



ΠΑΝΕΠΙΣΤΗΜΙΟ ΔΥΤΙΚΗΣ ΑΤΤΙΚΗΣ

ΣΧΟΛΗ ΜΗΧΑΝΙΚΩΝ

ΤΜΗΜΑ ΜΗΧΑΝΙΚΩΝ ΒΙΟΪΑΤΡΙΚΗΣ

**Διάγνωση της νόσου του Αλτσχάιμερ με
χρήση βαθιάς μάθησης και ανάλυσης
εικόνας**

ΝΙΚΟΛΑΟΣ ΘΕΟΚΡΙΤΟΣ ΤΣΟΠΑΝΙΔΗΣ

Αριθμός Μητρώου: 48016119

**Επιβλέπων Καθηγητής
Παντελεήμων Ασβεστάς, Καθηγητής**

Αθήνα 14/03/2024

ΔΙΑΓΝΩΣΗ ΤΗΣ ΝΟΣΟΥ ΤΟΥ ΑΛΤΣΧΑΙΜΕΡ ΜΕ ΧΡΗΣΗ ΒΑΘΙΑΣ ΜΑΘΗΣΗΣ ΚΑΙ
ΑΝΑΛΥΣΗΣ ΕΙΚΟΝΑΣ

Η Τριμελής Εξεταστική Επιτροπή

Ο Επιβλέπων Καθηγητής

Παντελεήμων Ασβεστάς

Καθηγητής

Δημήτριος Γκλώτσος

Καθηγητής

Σπυρίδων Κωστόπουλος

Αναπληρωτής Καθηγητής

--	--	--

ΔΗΛΩΣΗ ΣΥΓΓΡΑΦΕΑ ΔΙΠΛΩΜΑΤΙΚΗΣ ΕΡΓΑΣΙΑΣ

Ο υπογράφων Νικόλαος Θεόκριτος Τσοπανίδης του Αναστασίου, με αριθμό μητρώου 48016119 φοιτητής του Τμήματος Μηχανικών Βιοϊατρικής της Σχολής Μηχανικών του Πανεπιστημίου Δυτικής Αττικής, δηλώνω υπεύθυνα ότι:

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

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

Ημερομηνία

14/03/2024

Ο/Η Δηλών/ούσα

Νικόλαος Θεόκριτος Τσοπανίδης



Τσοπανίδης Νικόλαος

ΠΕΡΙΛΗΨΗ

Η διπλωματική εργασία παρουσιάζει την ανάπτυξη ενός κώδικα βασισμένου στη βαθιά μάθηση χρησιμοποιώντας το TensorFlow για την ταξινόμηση εικόνων εγκεφάλου MRI σε ασθενείς με Νόσο Αλτσχάιμερ (AD). Τα αρχικά κεφάλαια προσφέρουν μια επισκόπηση της νόσου του Αλτσχάιμερ, συζητώντας τα αίτια και τα συμπτώματά της και εμβαθύνουν σε διαγνωστικές τεχνικές, με έμφαση στην απεικόνιση MRI. Στη συνέχεια, η εργασία διερευνά τις θεωρητικές πτυχές της βαθιάς μάθησης, επισημαίνοντας τις πιθανές εφαρμογές της στην ιατρική διαγνωστική και συνοψίζοντας την αρχιτεκτονική και την αποτελεσματικότητα των τεχνικών βαθιάς μάθησης.

Ο πυρήνας της διπλωματικής εργασίας είναι αφιερωμένος στη μεθοδολογία ανάπτυξης και υλοποίησης του κώδικα, ο οποίος γράφτηκε σε Python χρησιμοποιώντας τις βιβλιοθήκες TensorFlow και Keras. Η διαδικασία περιλάμβανε την εκτέλεση του κώδικα, την ανάλυση των αποτελεσμάτων και την αντιμετώπιση προκλήσεων, ιδιαίτερα όσον αφορά την απόδοση του κώδικα. Αρχικά, ο κωδικός παρουσίαζε κακή απόδοση λόγω υπερπροσαρμογής. Ωστόσο, μέσω διαφόρων τροποποιήσεων και δοκιμών, επιτεύχθηκε οριακή βελτίωση στην απόδοση.

Μια σημαντική πρόκληση που αντιμετωπίστηκε ήταν το περιορισμένο μέγεθος του συνόλου των εικόνων εγκεφάλου MRI, ιδιαίτερα στις κατηγορίες "Moderate Demented" (Μέτριας Άνοιας) και "Mild Demented" (Ήπιας Άνοιας). Αυτός ο περιορισμός εμπόδιζε την ικανότητα του κώδικα να εκπαιδεύεται αποτελεσματικά και να αναγνωρίζει περίπλοκες λεπτομέρειες στις εικόνες για ακριβή ταξινόμηση. Αντίθετα, οι κατηγορίες "Non Demented" (Χωρίς Άνοια) και "Very Mild Demented" (Πολύ Ήπια Άνοια) παρουσίαζαν μεγαλύτερα σύνολα δεδομένων.

Συμπερασματικά, ενώ ο κώδικας που αναπτύχθηκε δείχνει δυνατότητες, η αποτελεσματικότητά του περιορίζεται από την έλλειψη εκτεταμένων δεδομένων. Η εργασία προτείνει ότι η επέκταση του συνόλου δεδομένων, ειδικά σε υποεκπροσωπούμενες κατηγορίες, θα μπορούσε να βελτιώσει σημαντικά την απόδοση και την ακρίβεια του κώδικα στην ταξινόμηση των σταδίων της νόσου του Αλτσχάιμερ.

Λέξεις Κλειδιά: Βαθιά μάθηση, Νόσος Αλτσχάιμερ, Διαγνωστικές τεχνικές, TensorFlow, Ταξινόμηση εικόνων, Ακρίβεια ταξινόμησης, Απόδοση κώδικα

ABSTRACT

The thesis presents the development of a deep learning-based code using TensorFlow to classify MRI brain images in Alzheimer's Disease (AD) patients. The opening chapters offer an overview of Alzheimer's disease, discussing its causes and symptoms, and delve into diagnostic techniques, with an emphasis on MRI imaging. The project then explores the theoretical aspects of deep learning, highlighting its potential applications in medical diagnostics and summarizing the architecture and effectiveness of deep learning techniques.

The core of the thesis is dedicated to the development and implementation methodology of the code, which was written in Python using the TensorFlow and Keras libraries. The process involved running the code, analyzing the results, and addressing challenges, particularly in terms of code performance. Initially, the code was performing poorly due to overfitting. However, through various tweaks and tests, a marginal improvement in performance was achieved.

A major challenge faced was the limited size of the MRI brain image set, particularly in the "Moderate Demented" and "Mild Demented" categories. This limitation hindered the code's ability to effectively train and recognize complex details in images for accurate classification. In contrast, the "Non Demented" and "Very Mild Demented" categories presented larger datasets.

In conclusion, while the developed code shows potential, its effectiveness is limited by the lack of extensive data. The work suggests that expanding the dataset, especially to underrepresented categories, could significantly improve the code's performance and accuracy in classifying Alzheimer's disease stages.

Keywords: Deep Learning, Alzheimer's Disease, Diagnostic Techniques, TensorFlow, Image Classification, Classification Accuracy, Code Performance

Ευχαριστίες:

Εκφράζω τις θερμές μου ευχαριστίες στους γονείς μου, των οποίων η αμέριστη συναισθηματική και οικονομική υποστήριξη ήταν καθοριστική κατά τη διάρκεια της δύσκολης διαδρομής ολοκλήρωσης αυτής της διπλωματικής εργασίας. Η πίστη τους στις δυνατότητές μου και οι θυσίες που έκαναν μου έδωσαν τη δύναμη και την ανθεκτικότητα να επιμείνω.

Είμαι πάρα πολύ ευγνώμων στη κοπέλα μου, η οποία υπήρξε ακρογωνιαίος λίθος υποστήριξης σε όλη αυτή τη διαδικασία. Η ακλόνητη πίστη της σε μένα, σε συνδυασμό με την ικανότητά της να με υποστηρίζει ψυχολογικά σε δύσκολες στιγμές, ήταν πηγή τεράστιας άνεσης και δύναμης.

Μια ιδιαίτερη σημείωση εκτίμησης πηγαίνει στους φίλους μου, των οποίων ο ρόλος στη ζωή μου αυτή την περίοδο δεν μπορεί να υπερεκτιμηθεί. Η συνεχής ενθάρρυνση και η εμπιστοσύνη τους στο πρόσωπό μου έπαιξε κρίσιμο ρόλο στο να με παρακινήσω και να επικεντρωθώ στον στόχο μου.

Θα ήθελα επίσης να εκφράσω τη βαθιά μου ευγνωμοσύνη στην ευρύτερη ακαδημαϊκή κοινότητα, φοιτητές, καθηγητές, επιστήμονες και όλους εκείνους που μοιράζονται γενναιόδωρα τις γνώσεις και την έρευνά τους. Οι δημοσιευμένες εργασίες τους όχι μόνο ενημέρωσαν και ενέπνευσαν αυτή τη διπλωματική αλλά συμβάλλουν σημαντικά στη συνεχή αναζήτηση της γνώσης και της καινοτομίας στον τομέα. Η διαθεσιμότητα τέτοιων πόρων συνέβαλε καθοριστικά στη διαμόρφωση του ακαδημαϊκού μου ταξιδιού και στην ολοκλήρωση αυτού του έργου.

Συμπερασματικά, το ταξίδι προς την ολοκλήρωση αυτής της διπλωματικής εργασίας έγινε δυνατό όχι μόνο μέσω των προσπαθειών μου αλλά και μέσω της αγάπης, της υποστήριξης και της πίστης αυτών των αξιόλογων ατόμων στη ζωή μου και της ανεκτίμητης συνεισφοράς της ευρύτερης ακαδημαϊκής κοινότητας. Σε αυτούς, οφείλω ένα χρέος ευγνωμοσύνης που δύσκολα μπορούν να εκφράσουν οι λέξεις.

ΠΕΡΙΕΧΟΜΕΝΟ

Εισαγωγή	13
1. Νόσος του Αλτσχάιμερ.....	15
1.1. Βασικές Πληροφορίες για τη νόσο	15
1.2. Επιδημιολογία και Επιπολασμός.....	16
1.3. Συμπτώματα	19
1.3.1. Συμπτώματα κατά στάδια.....	19
1.3.2. Η ατροφία του εγκεφάλου και η εξέλιξή της	20
1.4. Διαγνωστικές Μέθοδοι Και Κριτήρια.....	21
1.4.1. Νευροψυχολογικά Τεστ (MMSE & MoCA).....	22
1.4.2. Εξέταση Εγκεφαλονωτιαίου Υγρού (CSF)	23
1.4.3. Απεικονίσεις MRI & PET	23
1.5. Τεχνικές Απεικόνισης MRI & Έρευνα Στη Διάγνωση Της AD	26
2. Βαθιά Μάθηση	28
2.1. Εισαγωγή στη Βαθιά Μάθηση	28
2.2. Τεχνητά Νευρωνικά Δίκτυα (ANNs).....	29
2.3. Βαθιά Νευρωνικά Δίκτυα (DNNs).....	31
2.4. Τεχνικές Βαθιάς Μάθησης.....	31
2.4.1. Perceptron Πολλών Επιπέδων (MLP)	32
2.4.2. Επαναλαμβανόμενα Νευρωνικά Δίκτυα (RNN)	33
2.4.3. Συνελκτικά Νευρωνικά Δίκτυα (CNN)	35
2.5. Βασική Αρχιτεκτονική CNN.....	36
2.5.1. Επίπεδο Εισόδου (Input Layer)	36
2.5.2. Συνελκτικό Επίπεδο (Convolutional Layer).....	37
2.5.3. Συναρτήσεις Ενεργοποίησης	40
2.5.4. Επίπεδα Ομαδοποίησης (Pooling Layers).....	44
2.5.5. Πλήρως Συνδεδεμένα Επίπεδα (Fully Connected Layers)	45
2.5.6. Επίπεδο Εξόδου (Output Layer)	47
3. Μεθοδολογία	49
3.1. Εξοπλισμός και Λογισμικό	50
3.2. Χαρακτηριστικά των Δεδομένων.....	51
3.3. Προετοιμασία των δεδομένων για την εκπαίδευση του μοντέλου.....	52
3.4. Αρχιτεκτονική Μοντέλου.....	54
3.5. Εκπαίδευση Μοντέλου.....	58
3.5.1. Σύνταξη Μοντέλου	58
3.5.2. Προγραμματισμός Ρυθμού Μάθησης.....	59
3.5.3. Επανακλήσεις	59
3.5.4. Εκπαίδευση.....	59
3.6. Επικύρωση	60
3.7. Αξιολόγηση Μοντέλου	60
3.7.1. Επαναληψιμότητα.....	60
3.7.2. Βαθμολογία F1	61
3.7.3. Καμπύλη ROC & Μέτρηση AUC	61
3.7.4. Απώλεια Hamming.....	63
3.7.5. Μήτρα Σύγχυσης	64
3.7.6. Χαρτογράφηση Grad-CAM.....	65
3.8. Περιορισμοί και προκλήσεις	65
4. Αποτελέσματα Μελέτης	67
4.1. Αποτελέσματα με συνάρτηση ενεργοποίησης ReLU	67
4.2. Αποτελέσματα με συνάρτηση ενεργοποίησης Leaky ReLU	71

ΔΙΑΓΝΩΣΗ ΤΗΣ ΝΟΣΟΥ ΤΟΥ ΑΛΤΣΧΑΙΜΕΡ ΜΕ ΧΡΗΣΗ ΒΑΘΙΑΣ ΜΑΘΗΣΗΣ ΚΑΙ
ΑΝΑΛΥΣΗΣ ΕΙΚΟΝΑΣ

4.3.	Αποτελέσματα με συνάρτηση ενεργοποίησης PReLU	75
4.4.	Αποτελέσματα με συνάρτηση ενεργοποίησης ELU	79
4.5.	Γραφήματα συγκρίσεων απόδοσης μεταξύ συναρτήσεων ενεργοποίησης...	83
5.	Συζήτηση & Συμπεράσματα.....	86
5.1.	Σχολιασμός αποτελεσμάτων συνάρτησης ReLU	86
5.2.	Σχολιασμός αποτελεσμάτων συνάρτησης Leaky ReLU	89
5.3.	Σχολιασμός αποτελεσμάτων συνάρτησης PReLU.....	91
5.4.	Σχολιασμός αποτελεσμάτων συνάρτησης ELU	92
5.5.	Σχολιασμός γραφημάτων σύγκρισης μεταξύ των συναρτήσεων ενεργοποίησης.....	94
5.6.	Συμπέρασμα	99
5.7.	Συγκριτική Ανάλυση με Άλλες Μελέτες	100
5.8.	Ευρύτερη Δυνατότητα Βαθιάς Μάθησης στην Ιατρική Απεικόνιση	101
	Βιβλιογραφία	103

Κατάλογος Εικόνων

#	Τίτλος	Σελίδα
2.1.	MLP με δύο κρυφά επίπεδα	32
2.2.	Η αμφίδρομη ροή πληροφοριών μεταξύ των κρυφών επιπέδων ως κύριο χαρακτηριστικό των RNN	34
2.3.	Οπτικοποίηση δεδομένων που διέρχονται από ένα συνελκτικό νευρωνικό δίκτυο	36
2.4.	Λειτουργία συνέλιξης με φίλτρο (kernel) 3×3	37
2.5.	Ανίχνευση ακρών μέσω Γκαουσιανών φίλτρων	38
2.6.	Οπτική αναπαράσταση εξαγωγής περιπλοκότερων χαρακτηριστικών με τον συνδυασμό πολλαπλών συνελκτικών επιπέδων	38
2.7.	Γράφημα της συνάρτησης ενεργοποίησης ReLU	40
2.8.	Γράφημα της συνάρτησης ενεργοποίησης Leaky ReLU	41
2.9.	Γράφημα συνάρτησης ενεργοποίησης PReLU	42
2.10.	Γράφημα συνάρτησης ενεργοποίησης ELU για διαφορετικές σταθερές β	43
2.11.	Λειτουργία Επιπέδου Ομαδοποίησης (max pooling, average pooling)	44
2.12.	Ένα πλήρως συνδεδεμένο δίκτυο με είσοδο x1, x2, x3 και νευρώνες πυκνού επιπέδου n1, n2, n3, n4.	46
2.13.	Απεικόνιση δικτύου χωρίς τη τεχνική dropout (no dropout) και δικτύου με τη τεχνική dropout (with dropout) όπου παρατηρείται τυχαία απενεργοποίηση μερικών νευρώνων στα πυκνά πλήρως συνδεδεμένα επίπεδα του δικτύου	46
2.14.	Γραφική αναπαράσταση της συνάρτησης softmax	47
3.1.	Δείγματα εικόνων από κάθε κατηγορία	52
3.2.	Οπτικοποίηση Μοντέλου με χρήση `visualkeras.layered_view`	57
3.3.	Οπτικοποίηση Μοντέλου με χρήση συνάρτησης `plot_model`	58
3.4.	Η περιοχή κάτω από την καμπύλη ROC (AUC), σκιαγραφημένη.	62
3.5.	Αναπαράσταση μήτρας σύγχυσης	64
3.6.	Grad-CAM εφαρμοσμένο σε ακτινογραφίες θώρακος	65
4.1.	Γραφήματα των μετρήσεων απώλειας, ακρίβειας, επαναληψιμότητας, ανάκλησης, AUC και απώλειας hamming κατά τη διάρκεια εκπαίδευσης (μπλε γραμμή) και επικύρωσης (πορτοκαλί γραμμή) για το μοντέλο με συνάρτηση ενεργοποίησης ReLU	68
4.2.	Μήτρα Σύγχυσης των δεδομένων εικόνων κάθε σταδίου της νόσου Alzheimer και των προβλεπόμενων εικόνων του μοντέλου με συνάρτηση ενεργοποίησης ReLU.	69
4.3.	Καμπύλη ROC συνάρτησης ενεργοποίησης ReLU για κάθε κλάση της νόσου Alzheimer	70
4.4.	Καμπύλη Επαναληψιμότητας – Ανάκλησης συνάρτησης ενεργοποίησης ReLU για κάθε κλάση της νόσου Alzheimer	70
4.5.	Grad-CAM οπτικοποίηση μοντέλου με συνάρτηση ενεργοποίησης ReLU σε εικόνες MRI εγκεφάλων από το σετ δεδομένων εκπαίδευσης	71
4.6.	Γραφήματα μετρήσεων απώλειας, ακρίβειας, επαναληψιμότητας, ανάκλησης, AUC και απώλειας hamming κατά τη διάρκεια εκπαίδευσης (μπλε γραμμή) και επικύρωσης (πορτοκαλί γραμμή) για το μοντέλο με συνάρτηση ενεργοποίησης Leaky ReLU	72
4.7.	Μήτρα Σύγχυσης των δεδομένων εικόνων κάθε σταδίου της νόσου Alzheimer και των προβλεπόμενων εικόνων του μοντέλου με συνάρτηση ενεργοποίησης Leaky ReLU.	73
4.8.	Καμπύλη ROC συνάρτησης ενεργοποίησης Leaky ReLU για κάθε κλάση της νόσου Alzheimer	74
4.9.	Καμπύλη Επαναληψιμότητας – Ανάκλησης συνάρτησης ενεργοποίησης Leaky ReLU για κάθε κλάση της νόσου Alzheimer	74

ΔΙΑΓΝΩΣΗ ΤΗΣ ΝΟΣΟΥ ΤΟΥ ΑΛΤΣΧΑΙΜΕΡ ΜΕ ΧΡΗΣΗ ΒΑΘΙΑΣ ΜΑΘΗΣΗΣ ΚΑΙ
ΑΝΑΛΥΣΗΣ ΕΙΚΟΝΑΣ

4.10.	Grad-CAM οπτικοποίηση μοντέλου με συνάρτηση ενεργοποίησης Leaky ReLU σε εικόνες MRI εγκεφάλων από το σετ δεδομένων εκπαίδευσης	75
4.11.	Γραφήματα μετρήσεων απώλειας, ακρίβειας, επαναληψιμότητας, ανάκλησης, AUC και απώλειας hamming κατά τη διάρκεια εκπαίδευσης (μπλε γραμμή) και επικύρωσης (πορτοκαλί γραμμή) για το μοντέλο με συνάρτηση ενεργοποίησης PReLU	76
4.12.	Μήτρα Σύγχυσης των δεδομένων εικόνων κάθε σταδίου της νόσου Alzheimer και των προβλεπόμενων εικόνων του μοντέλου με συνάρτηση ενεργοποίησης PReLU.	77
4.13.	Καμπύλη ROC συνάρτησης ενεργοποίησης PReLU για κάθε κλάση της νόσου Alzheimer	78
4.14.	Καμπύλη Επαναληψιμότητας – Ανάκλησης συνάρτησης ενεργοποίησης PReLU για κάθε κλάση της νόσου Alzheimer	78
4.15.	Grad-CAM οπτικοποίηση μοντέλου με συνάρτηση ενεργοποίησης PReLU σε εικόνες MRI εγκεφάλων από το σετ δεδομένων εκπαίδευσης	79
4.16.	Γραφήματα μετρήσεων απώλειας, ακρίβειας, επαναληψιμότητας, ανάκλησης, AUC και απώλειας hamming κατά τη διάρκεια εκπαίδευσης (μπλε γραμμή) και επικύρωσης (πορτοκαλί γραμμή) για το μοντέλο με συνάρτηση ενεργοποίησης ELU	80
4.17.	Μήτρα Σύγχυσης των δεδομένων εικόνων κάθε σταδίου της νόσου Alzheimer και των προβλεπόμενων εικόνων του μοντέλου με συνάρτηση ενεργοποίησης ELU.	81
4.18.	Καμπύλη ROC συνάρτησης ενεργοποίησης ELU για κάθε κλάση της νόσου Alzheimer	82
4.19.	Καμπύλη Επαναληψιμότητας – Ανάκλησης συνάρτησης ενεργοποίησης ELU για κάθε κλάση της νόσου Alzheimer	82
4.20.	Grad-CAM οπτικοποίηση μοντέλου με συνάρτηση ενεργοποίησης ELU σε εικόνες MRI εγκεφάλων από το σετ δεδομένων εκπαίδευσης	83
4.21.	Γράφημα σύγκρισης AUC μεταξύ συναρτήσεων ενεργοποίησης σε epochs	84
4.22.	Γράφημα σύγκρισης απώλειας μεταξύ συναρτήσεων ενεργοποίησης σε epochs	84
4.23.	1 ^ο Γράφημα: Καμπύλες ROC των συναρτήσεων ενεργοποίησης για τη κατηγορία δεδομένων MildDementia (ήπια άνοια), 2 ^ο Γράφημα: Καμπύλες επαναληψιμότητας – ανάκλησης των συναρτήσεων ενεργοποίησης για τη κατηγορία δεδομένων MildDementia	84
4.24.	1 ^ο Γράφημα: Καμπύλες ROC των συναρτήσεων ενεργοποίησης για τη κατηγορία δεδομένων ModerateDementia (μέτρια άνοια), 2 ^ο Γράφημα: Καμπύλες επαναληψιμότητας – ανάκλησης των συναρτήσεων ενεργοποίησης για τη κατηγορία δεδομένων ModerateDementia	84
4.25.	1 ^ο Γράφημα: Καμπύλες ROC των συναρτήσεων ενεργοποίησης για τη κατηγορία δεδομένων NonDementia (χωρίς άνοια), 2 ^ο Γράφημα: Καμπύλες επαναληψιμότητας – ανάκλησης των συναρτήσεων ενεργοποίησης για τη κατηγορία δεδομένων NonDementia	85
4.26.	1 ^ο Γράφημα: Καμπύλες ROC των συναρτήσεων ενεργοποίησης για τη κατηγορία δεδομένων VeryMildDementia (πολύ ήπια άνοια), 2 ^ο Γράφημα: Καμπύλες επαναληψιμότητας – ανάκλησης των συναρτήσεων ενεργοποίησης για τη κατηγορία δεδομένων VeryMildDementia	85

Κατάλογος Πινάκων

#	Τίτλος	Σελίδα
1.1.	Επιπολασμός κλινικής άνοιας AD	17
4.1.	Τελικές τιμές μετρήσεων του μοντέλου με συνάρτηση ενεργοποίησης	67

4.2.	ReLU από το αρχείο καταγραφής Τιμές μετρήσεων με συνάρτηση ενεργοποίησης ReLU σε κάθε στάδιο της νόσου Alzheimer	69
4.3.	Τελικές τιμές μετρήσεων του μοντέλου με συνάρτηση ενεργοποίησης Leaky ReLU από το αρχείο καταγραφής	72
4.4.	Τιμές μετρήσεων με συνάρτηση ενεργοποίησης Leaky ReLU σε κάθε στάδιο της νόσου Alzheimer	73
4.5.	Τελικές τιμές μετρήσεων του μοντέλου με συνάρτηση ενεργοποίησης PReLU από το αρχείο καταγραφής	76
4.6.	Τιμές μετρήσεων με συνάρτηση ενεργοποίησης PReLU σε κάθε στάδιο της νόσου Alzheimer	77
4.7.	Τελικές τιμές μετρήσεων του μοντέλου με συνάρτηση ενεργοποίησης ELU από το αρχείο καταγραφής	80
4.8.	Τιμές μετρήσεων με συνάρτηση ενεργοποίησης ELU σε κάθε στάδιο της νόσου Alzheimer	81

Κατάλογος Συντομογραφιών

DL	Deep Learning (Βαθιά Μάθηση)
ML	Machine Learning (Μηχανική Μάθηση)
AI	Artificial Intelligence (Τεχνητή Νοημοσύνη)
AD	Alzheimer's Disease (Νόσος του Αλτσχάιμερ)
MRI	Magnetic Resonance Tomography (Μαγνητική Τομογραφία)
PET	Positron Emission Tomography (Τομογραφία εκπομπής ποζιτρονίων)
CT	Computed Tomography scan (Αξονική Τομογραφία)
LOAD	Late Onset Alzheimer's Disease (Νόσος του Αλτσχάιμερ όψιμης έναρξης)
Apo-E	Apolipoprotein E (Απολιποπρωτεΐνη E)
MCI	Mild Cognitive Impairment (Ηπια Γνωσιακή Εξασθένιση)
MMSE	Mini-Mental State Examination (Εξέταση Σύντομης Ψυχικής Κατάστασης)
MoCA	Montreal Cognitive Assessment (Γνωσιακή Αξιολόγηση του Μόντρεαλ)
tau	tubulin associated unit (μονάδα που σχετίζεται με τουμπουλίνη)
CSF	Εγκεφαλονωτιαίο Υγρό - Cerebrospinal fluid
NIA-AA	National Institute on Aging and Alzheimer's Association (Εθνικό Ινστιτούτο για τη Γήρανση και την Ένωση Αλτσχάιμερ)
IWG	International Workplace Group (Διεθνή Ομάδα Εργασίας)
DSM-5	Diagnostic and Statistical Manual of Mental Disorders, 5th Edition
ICD-11	International Classification of Diseases 11th Edition
INSECT	Intensity-Normalized Stereotaxic Environment for Classification of Tissues (Στερεοταξικό Περιβάλλον Κανονικοποιημένης Ένταση για Ταξινόμηση Ιστών)
ANIMAL	Automated Non-linear Image Matching and Anatomical Labeling (Αυτοματοποιημένη Μη Γραμμική Τεχνική Αντιστοίχισης Εικόνας και Ανατομικής Επισήμανσης)
CLASP	Constrained Laplacian Anatomical Segmentation (Περιορισμένη Λαπλασιανή Ανατομική Τμηματοποίηση)
ADNI	Alzheimer's Disease Neuroimaging Initiative (Πρωτοβουλία Νευροαπεικόνισης για τη Νόσο του Αλτσχάιμερ)
DTI	Diffusion Tensor Imaging (Απεικόνιση Τανυστή Διάχυσης)
ASL	Arterial Spin Labeling (Σήμανση Αρτηριακού Σπιν)

CBF	Cerebral Blood Flow (Εγκεφαλική Ροή Αίματος)
MRS	Magnetic Resonance Spectroscopy (Φασματοσκοπία Μαγνητικού Συντονισμού)
fMRI	Functional Magnetic Resonance Imaging (Λειτουργική Απεικόνιση Μαγνητικού Συντονισμού)
ANNs	Artificial Neural Networks (Τεχνητά Νευρωνικά Δίκτυα)
DNNs	Deep Neural Networks (Βαθιά Νευρωνικά Δίκτυα)
MLP	Multi-layer Perceptron (Perceptron Πολλαπλών Επιπέδων)
CNN	Convolutional Neural Network (Συνελκτικό Νευρωνικό Δίκτυο)
RNN	Recurrent Neural Network (Επαναλαμβανόμενο Νευρωνικό Δίκτυο)
SLP	Single Layer Perceptron (Perceptron Μονού Επιπέδου)
SGD	Stochastic Gradient Descent (Στοχαστική κλίση κατάβασης)
Adam	Adaptive Moment Estimation (Προσαρμοστική Εκτίμηση Ροπής)
tanh	Hyperbolic Tangent Function (Υπερβολική Συνάρτηση Εφαπτομένης)
LSTM	Long Short-Term Memory network (Δίκτυο Μακρο-βραχυπρόθεσμης Μνήμης)
AlexNet	Συνελκτικό Νευρωνικό Δίκτυο σχεδιασμένο από τον Alex Krizhevsky
VGG	Visual Geometry Group Network (Δίκτυο της Ομάδας Ψηφιακής Γεωμετρίας)
ResNet	Residual neural network (Υπολειμματικό Νευρωνικό Δίκτυο)
ReLU	Rectified Linear Unit (Διορθωμένη Γραμμική Μονάδα)
ELU	Exponential Linear Unit (Εκθετική Γραμμική Μονάδα)
AUC	Area Under the ROC Curve (Περιοχή Κάτω από την καμπύλη ROC)
PR	Precision – Recall (Επαναληψιμότητα – Ανάκληση)
ROC	Receiver Operating Characteristic curve (Καμπύλη Χαρακτηριστικών Λειτουργίας Δείκτη)
TPR	True Positive Rate (Αληθώς Θετικό Ποσοστό)
FPR	False Positive Rate (Ψευδώς Θετικό Ποσοστό)
Grad-CAM	Gradient-weighted Class Activation Mapping (Χαρτογράφηση Ενεργοποίησης Κλάσης με Σταθμισμένη Κλίση)

Εισαγωγή

Η βαθιά μάθηση (Deep Learning - DL) είναι ένα υποπεδίο της μηχανικής μάθησης (Machine Learning – ML), το οποίο με τη σειρά του εμπίπτει στην ευρύτερη ομπρέλα της τεχνητής νοημοσύνης (Artificial Intelligence – AI). Χαρακτηρίζεται από τη χρήση τεχνητών νευρωνικών δικτύων, ιδιαίτερα βαθιών δικτύων με πολλά επίπεδα, εξ ου και ο όρος βαθιά μάθηση. Αυτά τα νευρωνικά δίκτυα αποτελούνται από κόμβους, ή νευρώνες, που συνδέονται με ακμές ή βάρη, τα οποία προσαρμόζονται κατά τη διάρκεια της εκπαιδευτικής διαδικασίας. Τα θεμελιώδη δομικά στοιχεία της DL είναι τεχνητοί νευρώνες ή κόμβοι, που μιμούνται τη βιολογική δομή του ανθρώπινου εγκεφάλου σε κάποιο βαθμό. Κάθε νευρώνας λαμβάνει είσοδο, την επεξεργάζεται και μεταβιβάζει την έξοδο του στο επόμενο στρώμα. Το "βαθύ" στη βαθιά μάθηση αναφέρεται στην παρουσία πολλαπλών τέτοιων επιπέδων, τα οποία επιτρέπουν στο δίκτυο να μάθει περίπλοκες, ιεραρχικές αναπαραστάσεις των δεδομένων εισόδου.

Ένα βασικό χαρακτηριστικό της DL είναι η ικανότητά της να εκτελεί αυτόματα εξαγωγή χαρακτηριστικών. Οι παραδοσιακές τεχνικές ML βασίζονται συχνά στη χειροκίνητη εξαγωγή χαρακτηριστικών, όπου τα σχετικά χαρακτηριστικά των δεδομένων προσδιορίζονται και εξάγονται από ειδικούς. Αντίθετα, οι αλγόριθμοι DL μπορούν να μάθουν αυτές τις λειτουργίες απευθείας από τα δεδομένα, καθιστώντας τις ιδιαίτερα χρήσιμες για εργασίες όπου η χειροκίνητη εξαγωγή χαρακτηριστικών είναι δύσκολη ή ανέφικτη, όπως η αναγνώριση εικόνας και ομιλίας. Τα μοντέλα DL εκπαιδεύονται χρησιμοποιώντας μεγάλο όγκο δεδομένων με ετικέτα και μια αρχιτεκτονική νευρωνικών δικτύων που είναι κατάλληλη για την εκάστοτε εργασία. Κατά τη διάρκεια της εκπαίδευσης, το μοντέλο προσαρμόζει τα βάρη του μέσω μιας διαδικασίας γνωστής ως οπισθο-διάδοση (back-propagation), η οποία περιλαμβάνει τον υπολογισμό της κλίσης της συνάρτησης απώλειας (ένα μέτρο του σφάλματος πρόβλεψης του μοντέλου) και τη χρήση αυτών των πληροφοριών για την ενημέρωση των βαρών σε μια κατεύθυνση που ελαχιστοποιεί το σφάλμα.

Ένας από τους λόγους για την αύξηση της δημοτικότητας της DL τα τελευταία χρόνια είναι η αύξηση της υπολογιστικής ισχύος και η διαθεσιμότητα μεγάλων συνόλων δεδομένων, τα οποία είναι απαραίτητα για την εκπαίδευση των βαθιών νευρωνικών δικτύων (Deep Neural Networks – DNNs). Οι εφαρμογές της DL είναι τεράστιες και περιλαμβάνουν τομείς όπως η επεξεργασία φυσικής γλώσσας, η όραση υπολογιστή, η αναγνώριση ομιλίας, ακόμη και η ιατρική διάγνωση. Στο πλαίσιο της ταξινόμησης ιατρικών εικόνων, η DL έχει δείξει εξαιρετική ικανότητα. Μπορεί να αναλύσει σύνθετες ιατρικές εικόνες όπως ακτινογραφίες, μαγνητικές τομογραφίες (MRI) και αξονικές τομογραφίες (CT), εντοπίζοντας μοτίβα και ανωμαλίες που μπορεί να είναι ενδεικτικές ορισμένων ασθενειών ή καταστάσεων. Αυτή η ικανότητα έχει τη δυνατότητα να βοηθήσει σημαντικά στις διαγνωστικές διαδικασίες, ενισχύοντας τόσο την ταχύτητα όσο και την ακρίβεια των ιατρικών αξιολογήσεων.

Ένα ισχυρό παράδειγμα είναι ότι η DL είναι έτοιμη να φέρει επανάσταση στη διάγνωση και τη διαχείριση της νόσου του Αλτσχάιμερ (AD), μιας προοδευτικής νευροεκφυλιστικής διαταραχής. Η εφαρμογή της DL σε αυτόν τον τομέα γίνεται κυρίως μέσω της ανάλυσης δεδομένων ιατρικής απεικόνισης, όπως η MRI και η τομογραφία εκπομπής ποζιτρονίων (PET), μαζί με άλλες μορφές κλινικών δεδομένων. Στον τομέα της διάγνωσης, οι αλγόριθμοι DL είναι ιδιαίτερα ικανοί στον εντοπισμό λεπτών προτύπων στην απεικόνιση του εγκεφάλου που μπορεί να είναι ενδεικτικές των πρώιμων σταδίων της AD. Αυτά τα μοτίβα συχνά ξεφεύγουν από τις συμβατικές διαγνωστικές μεθόδους και τους ειδικούς του ανθρώπου, ειδικά στα αρχικά στάδια όταν οι παρεμβάσεις μπορεί να είναι πιο αποτελεσματικές. Με την

εκπαίδευση σε μεγάλα σύνολα δεδομένων εικόνων εγκεφάλου, τόσο υγιών όσο και εκείνων που επηρεάζονται από την AD, τα μοντέλα DL αναπτύσσουν την ικανότητα να ανιχνεύουν μικρές αλλαγές στη δομή ή τη λειτουργία του εγκεφάλου.

Η DL υπόσχεται σημαντική για την προώθηση της κατανόησης και της διαχείρισης της AD. Η ικανότητά του να επεξεργάζεται και να εξάγει ουσιαστικές γνώσεις από πολύπλοκα ιατρικά δεδομένα έχει τη δυνατότητα να μεταμορφώσει το τοπίο της διάγνωσης, της θεραπείας και της έρευνας του Αλτσχάιμερ, ανοίγοντας το δρόμο για πιο αποτελεσματικές και εξατομικευμένες λύσεις υγειονομικής περίθαλψης. Ωστόσο, η εφαρμογή της DL σε αυτό το πλαίσιο δεν είναι χωρίς προκλήσεις. Η ανάγκη για μεγάλα, ποικίλα και υψηλής ποιότητας σύνολα δεδομένων είναι πρωταρχικής σημασίας για την αποτελεσματική εκπαίδευση αυτών των μοντέλων. Πρέπει επίσης να αντιμετωπιστούν ζητήματα όπως το απόρρητο των δεδομένων, η τυποποίηση και η διαλειτουργικότητα.

Αυτή η διπλωματική, επομένως, καθοδηγείται από το κίνητρο να αξιοποιηθεί η δύναμη της DL για την ανάλυση εικόνων MRI, ένα τυπικό εργαλείο για την αξιολόγηση των νευρολογικών καταστάσεων. Η ικανότητα της να ανιχνεύει ανεπαίσθητες αλλαγές στη δομή ή τη λειτουργία του εγκεφάλου έχει τεράστιες δυνατότητες στον εντοπισμό πρώιμων δεικτών της AD. Εκπαιδεύοντας εξελιγμένα μοντέλα σε εκτεταμένα σύνολα δεδομένων μαγνητικής τομογραφίας, η έρευνα στοχεύει να αναπτύξει ένα σύστημα ικανό να διακρίνει μεταξύ των φυσιολογικών προτύπων και εκείνων που ενδεικτικά της νόσου.

Σε αυτήν την εργασία, το ταξίδι ξεκινά με μια επισκόπηση της AD, εστιάζοντας στη διάγνυσή της μέσω απεικόνισης MRI, και στη συνέχεια εμβαθύνει στο θεωρητικό πλαίσιο της DL, χρησιμοποιώντας “TensorFlow” και “Python”. Η καρδιά της εργασίας περιλαμβάνει την ανάπτυξη και τη βελτίωση ενός κώδικα για την ταξινόμηση εικόνων MRI ασθενών, αντιμετώπιση προκλήσεων όπως η υπερπροσαρμογή (overfitting) και ο περιορισμός δεδομένων, ιδιαίτερα σε ορισμένα στάδια της νόσου. Παρά τα εμπόδια αυτά, γίνονται σταδιακές βελτιώσεις. Η διατριβή ολοκληρώνεται υπογραμμίζοντας την ανάγκη για ένα πιο εκτεταμένο σύνολο δεδομένων για την ενίσχυση της αποτελεσματικότητας του κώδικα στην ακριβή ταξινόμηση των σταδίων της νόσου.

1. Νόσος του Αλτσχάιμερ

Ξεκινώντας με μια περιεκτική επισκόπηση των βασικών πληροφοριών για τη AD, καθιερώθηκε μια θεμελιώδη γνώση που θέτει το έδαφος για μια βαθύτερη έρευνα. Στη συνέχεια αναφέρεται μια λεπτομερής ανάλυση της επιδημιολογίας και του επιπολασμού της νόσου, ρίχνοντας φως στον παγκόσμιο αντίκτυπό της και τις δημογραφικές αποχρώσεις που χαρακτηρίζουν την κατανομή της.

Η συμπτωματολογία αναλύεται σε συμπτώματα πρώιμου, μεσαίου και τελικού σταδίου, παρέχοντας μια λεπτομερή εικόνα της εξέλιξης της νόσου και των ποικίλων προκλήσεων που παρουσιάζει σε κάθε συγκυρία. Αυτή η κατάτμηση όχι μόνο βοηθά στην κατανόηση της κλινικής εξέλιξης της AD, αλλά υπογραμμίζει επίσης τη σημασία της έγκαιρης και ακριβούς διάγνωσης. Για το σκοπό αυτό, εξετάζονται διαγνωστικές μέθοδοι και κριτήρια, από νευροψυχολογικές εξετάσεις έως αναλύσεις εγκεφαλονωτιαίου υγρού, καθώς και ο κεντρικός ρόλος της απεικόνισης MRI και PET στο σύγχρονο διαγνωστικό τοπίο. Η εξερεύνηση των τεχνικών απεικόνισης μαγνητικής τομογραφίας και οι ερευνητικές εφαρμογές τους στη διάγνωση της AD υπογραμμίζουν τις προόδους στην τεχνολογία και τη μεθοδολογία που ξεπερνούν τα όρια αυτού που καταλαβαίνουμε για αυτήν την περίπλοκη κατάσταση.

1.1. Βασικές Πληροφορίες για τη νόσο

Η νόσος Alzheimer (AD) είναι μια προοδευτική νευροεκφυλιστική διαταραχή και η κύρια αιτία της άνοιας. Η άνοια αναφέρεται γενικά σε μια σημαντική μείωση της γνωστικής λειτουργίας που επηρεάζει την καθημερινή ζωή, με τη AD να είναι ένας ξεχωριστός τύπος που χαρακτηρίζεται από συγκεκριμένες αλλαγές στον εγκέφαλο. Αυτές οι αλλαγές περιλαμβάνουν τη συσσώρευση μη φυσιολογικών εναποθέσεων πρωτεϊνών, δηλαδή β-αμυλοειδών πλακών στους εξωκυτταρικούς χώρους του εγκεφάλου και νευροϊνιδίων που περιέχουν πρωτεΐνες ταυ εντός των νευρώνων. Αυτές οι παθολογικές αλλαγές έχουν ως αποτέλεσμα την προοδευτική επιδείνωση των γνωστικών λειτουργιών. Τα αρχικά συμπτώματα της AD περιλαμβάνουν συχνά προβλήματα με τη βραχυπρόθεσμη μνήμη, αλλά η διαταραχή βλάπτει επίσης τη γλώσσα, τις οπτικοχωρικές δεξιότητες και τις εκτελεστικές λειτουργίες. Συμπεριφορικά και ψυχολογικά συμπτώματα όπως εναλλαγές διάθεσης, διέγερση και αλλαγές προσωπικότητας είναι επίσης συχνά στην AD. Η ασθένεια συνήθως αναπτύσσεται αργά, με τα συμπτώματα να εντείνονται με την πάροδο του χρόνου, οδηγώντας σε βαθιά απώλεια γνωστικών και λειτουργικών ικανοτήτων. Η AD είναι η κύρια αιτία άνοιας, καθώς υπολογίζεται ότι αντιπροσωπεύει το 60-70% όλων των περιπτώσεων άνοιας. Αυτό υπογραμμίζει τη σημαντική επίδραση της AD στη δημόσια υγεία και υπογραμμίζει τη σημασία της συνεχούς έρευνας και ανάπτυξης θεραπείας [1][2].

Το πιο πρώιμο και πιο κοινό σύμπτωμα της AD είναι η απώλεια μνήμης, που επηρεάζει ιδιαίτερα τη βραχυπρόθεσμη μνήμη. Στα αρχικά στάδια, τα άτομα με AD συχνά δυσκολεύονται να θυμηθούν πρόσφατα γεγονότα, συνομιλίες ή ραντεβού. Μπορεί να δυσκολεύονται να ανακαλέσουν τα ονόματα των νέων γνωστών τους, να τοποθετούν συχνά σε λάθος αντικείμενα και να θεωρούν δύσκολη τη διατήρηση νέων πληροφοριών, όπως τη θέση των καθημερινών αντικειμένων ή λεπτομέρειες των πρόσφατων γευμάτων. Αυτό το πρώιμο σύμπτωμα της εξασθένησης της μνήμης είναι ένας κρίσιμος δείκτης για τη διάγνωση και την κατανόηση της εξέλιξης της AD [1].

Η εξασθένηση της μνήμης στην AD αρχίζει συνήθως διακριτικά αλλά επιδεινώνεται προοδευτικά. Παράλληλα με την απώλεια μνήμης, η AD εκδηλώνεται μέσω διαφόρων γνωστικών και συμπεριφορικών αλλαγών, συμπεριλαμβανομένων

των γλωσσικών δυσκολιών, όπου τα άτομα μπορεί να δυσκολεύονται να βρουν τις σωστές λέξεις, να επαναλαμβάνονται στις συνομιλίες ή να δυσκολεύονται να κατανοήσουν τους άλλους. Η εκτελεστική λειτουργία επηρεάζεται επίσης σημαντικά, καθώς τα άτομα με AD συχνά βρίσκουν δύσκολο το σχεδιασμό, την οργάνωση εργασιών και τη λήψη αποφάσεων. Αυτό μπορεί να επηρεάσει σημαντικά τις καθημερινές δραστηριότητες, όπως η διαχείριση οικονομικών ή η ολοκλήρωση πολύπλοκων εργασιών. Επιπλέον, ο αποπροσανατολισμός είναι συχνός, με τα άτομα να δυσκολεύονται να αναγνωρίσουν οικεία μέρη ή να κατανοήσουν την ώρα της ημέρας. Συναισθηματικές διαταραχές, όπως αυξημένη ευερεθιστότητα, άγχος ή κατάθλιψη, συχνά συνοδεύουν αυτές τις γνωστικές αλλαγές. Οι αλλοιώσεις της προσωπικότητας, όπου τα άτομα υφίστανται έντονες αλλαγές στα χαρακτηριστικά τους, είναι επίσης εμφανείς. Οι μειωμένες οπτικοχωρικές δεξιότητες, που οδηγούν σε ζητήματα όπως η απώλεια σε οικεία περιβάλλοντα ή οι δυσκολίες με τις χωρικές σχέσεις, προσθέτουν περαιτέρω στην πολυπλοκότητα των συμπτωμάτων που βιώνουν τα άτομα με AD [3].

Η πορεία και η διάρκεια της AD ποικίλλει ευρέως μεταξύ των ατόμων. Κατά μέσο όρο, τα άτομα που έχουν διαγνωστεί με AD μπορεί να ζήσουν για περίπου 3 έως 9 χρόνια μετά τη διάγνωση, αν και μερικά μπορεί να ζήσουν περισσότερο. Η διάρκεια ζωής ενός ατόμου με AD εξαρτάται από πολλούς παράγοντες, συμπεριλαμβανομένης της ηλικίας στην οποία εμφανίζονται για πρώτη φορά τα συμπτώματα, του συγκεκριμένου υποτύπου της AD και της συνολικής ποιότητας υγείας και φροντίδας που λαμβάνουν. [4][5]

Η κατανόηση των ακριβών αιτιών της AD είναι περίπλοκη και συνεχής. Η τρέχουσα σκέψη υποδηλώνει ότι η AD πιθανότατα προκύπτει από έναν συνδυασμό γενετικών παραγόντων, περιβαλλοντικών επιρροών και αλλαγών που σχετίζονται με την ηλικία στον εγκέφαλο. Ένας σημαντικός γενετικός παράγοντας κινδύνου είναι η παρουσία του αλληλόμορφου απολιποπρωτεΐνης E (Apo-E) ε4, που σχετίζεται ιδιαίτερα με την όψιμη έναρξη της νόσου του Αλτσχάιμερ (LOAD), την πιο κοινή μορφή της νόσου. [6][7][8]

Εκτός από τους γενετικούς παράγοντες, αρκετοί άλλοι παράγοντες κινδύνου είναι αξιοσημείωτοι για την AD. Ο κίνδυνος εμφάνισης AD αυξάνεται με την ηλικία. Η καρδιαγγειακή υγεία είναι επίσης ζωτικής σημασίας, καθώς καταστάσεις που επηρεάζουν την υγεία των αιμοφόρων αγγείων, όπως η υπέρταση, η υψηλή χοληστερόλη, ο διαβήτης και η παχυσαρκία, μπορεί να οδηγήσουν σε γνωστική εξασθένηση. Παράγοντες του τρόπου ζωής, όπως η καθιστική ζωή, η έλλειψη ψυχικής διέγερσης, η κοινωνική απομόνωση και η κακή διατροφή, μπορούν επίσης να αυξήσουν τον κίνδυνο AD. Επιπλέον, το χρόνιο στρες και η κατάθλιψη μπορούν να επηρεάσουν αρνητικά την υγεία του εγκεφάλου και να συμβάλουν στη γνωστική εξασθένηση. Τέλος, η τραυματική εγκεφαλική κάκωση (TBI), συμπεριλαμβανομένων των επαναλαμβανόμενων κρανιοεγκεφαλικών κακώσεων που προκαλούνται συχνά σε αθλήματα επαφής ή στρατιωτική θητεία, αναγνωρίζεται ως πιθανός παράγοντας κινδύνου για την μετέπειτα ανάπτυξη της AD. [3][9]

1.2.Επιδημιολογία και Επιπολασμός

Η AD χαρακτηρίζεται από γνωστική εξασθένηση, απώλεια μνήμης και μειωμένη ικανότητα εκτέλεσης καθημερινών λειτουργιών. Είναι η πιο διαδεδομένη μορφή άνοιας, που επηρεάζει κυρίως τους ηλικιωμένους, αν και δεν είναι αποκλειστική σε αυτήν την ηλικιακή ομάδα. Ο προοδευτικός εκφυλισμός των εγκεφαλικών κυττάρων στη AD οδηγεί σε μείωση των δεξιοτήτων μνήμης και σκέψης, επηρεάζοντας σημαντικά την ικανότητα του ατόμου να εκτελεί εργασίες ρουτίνας. Αυτή η

κατάσταση θέτει μια σημαντική πρόκληση για τη δημόσια υγεία παγκοσμίως, με έναν αυξανόμενο αριθμό ατόμων που ζουν με AD ή σχετικές άνοιες. Καθώς ο παγκόσμιος πληθυσμός γερνάει, η επίπτωση της AD αναμένεται να αυξηθεί σημαντικά, αυξάνοντας έτσι την πίεση στα συστήματα υγειονομικής περίθαλψης και στην κοινωνία γενικότερα. Η επιρροή της AD υπερβαίνει τα άτομα που επηρεάζονται άμεσα. επηρεάζει βαθιά τις οικογένειες, τους φροντιστές και τις κοινότητές τους, απαιτώντας σημαντικούς πόρους, συναισθηματική υποστήριξη και οικονομικές επενδύσεις.

Ο επιπολασμός της νόσου αυξάνεται σημαντικά με την ηλικία σύμφωνα με την έρευνα του Monfared et. al (2022), υπογραμμίζοντας τη σχέση της νόσου με τη διαδικασία της γήρανσης. Στην Κίνα, για παράδειγμα, ο επιπολασμός της AD αυξάνεται απότομα από μόλις 0,2% σε άτομα ηλικίας 55–59 ετών σε εκπληκτικό 48,2% σε άτομα ηλικίας 95–99 ετών (βλ. Πίνακας 1.2.1.). Επιπλέον, η νόσος καταδεικνύει μια ανισότητα μεταξύ των φύλων, καθώς είναι πιο διαδεδομένη στις γυναίκες, όπως έχουν δείξει διάφορες μελέτες. Τα ποσοστά θνησιμότητας που σχετίζονται με την άνοια, συμπεριλαμβανομένης της AD, την υποδηλώνουν ως κύρια αιτία θανάτου παγκοσμίως, με τέτοια ποσοστά σε ανοδική τροχιά παράλληλα με τη γήρανση του πληθυσμού. Συγκεκριμένα, στην Ευρώπη, το τυποποιημένο για την ηλικία ποσοστό θνησιμότητας για την άνοια AD ήταν 45,2% ανά 100.000 το 2013 και στις Ηνωμένες Πολιτείες, το 46,4% των θανάτων που σχετίζονται με την άνοια αποδίδονταν στην AD.

Τα άτομα με ήπια γνωστική εξασθένηση (MCI) λόγω AD έχουν αυξημένη πιθανότητα να εξελιχθούν σε άνοια, ιδιαίτερα όταν υπάρχουν βιοδείκτες που σχετίζονται με την AD. Τα κλινικά διαγνωσμένα ποσοστά εμφάνισης MCI κυμαίνονται, με μελέτες που δείχνουν ποσοστά που κυμαίνονται από 22,5% έως 60,1% ανά 1000 άτομα-έτος, που ποικίλλουν ανάλογα με την ηλικία. Στην Κίνα, ο επιπολασμός MCI αναφέρεται ότι κυμαίνεται μεταξύ 12,2% και 27,8%, με υψηλότερα ποσοστά να εντοπίζονται μεταξύ των ατόμων με χαμηλότερο μορφωτικό επίπεδο και εκείνων που ζουν μόνοι. [10]

Πίνακας 1.1 Επιπολασμός κλινικής άνοιας AD [10]

Συγγραφέας, έτος	Τοποθεσία (έτος)	Ηλικία Πληθυσμού	Ασθενείς με άνοια AD, %	Ασθενείς με άνοια AD, n
<i>Fiest 2016 [11]</i>	Πολλές χώρες*	Ηλικίας ≥ 60 ετών	Περιοδικός επιπολασμός 3,04%	μη διαθέσιμο
			Σημειακός επιπολασμός 4,02%	
<i>Takizawa 2015 [12]</i>	Γαλλία (2009)	Ηλικίας ≥ 60 ετών	3,0%	μη διαθέσιμο
	Ιταλία (2000)	Ηλικίας ≥ 64 ετών	4,2%	μη διαθέσιμο
	Ισπανία (2009)	Ηλικίας ≥ 75 ετών	6,4%	μη διαθέσιμο
	Ηνωμένο Βασίλειο (μη διαθέσιμο)	μη διαθέσιμο	4,9%	μη διαθέσιμο
	ΗΠΑ (2001)	Ηλικίας ≥	6,8%	μη διαθέσιμο

ΔΙΑΓΝΩΣΗ ΤΗΣ ΝΟΣΟΥ ΤΟΥ ΑΛΤΣΧΑΙΜΕΡ ΜΕ ΧΡΗΣΗ ΒΑΘΙΑΣ ΜΑΘΗΣΗΣ ΚΑΙ
ΑΝΑΛΥΣΗΣ ΕΙΚΟΝΑΣ

		70 ετών		
<i>Niu 2017 [13]</i>	Ευρώπη**	Διάφορες ηλικίες **	5,1%	μη διαθέσιμο
<i>Ciu 2020 [14]</i>	Κίνα (2019)	Ηλικίας ≥ 60 ετών	3.8%	μη διαθέσιμο
<i>Chan 2013 [15]</i>	Κίνα (2010)	Ηλικίας ≥ 55 ετών	55–59 ετών: 0,2%	5,69 εκατ
			60–64 ετών: 0,6%	
			65–69 ετών: 1,3%	
			70–74 ετών: 2,7%	
			75–79 ετών: 5,5%	
			80–84 ετών: 10,4%	
			85–89 ετών: 18,5%	
			90–94 ετών: 30,9%	
			95–99 ετών: 48,2%	
<i>Zhao 2020 [16]</i>	Κίνα ***	μη διαθέσιμο	4.0%	μη διαθέσιμο
<i>Brookmeyer 2018 [17]</i>	ΗΠΑ (2017)	μη διαθέσιμο	μη διαθέσιμο	6,08 εκατ

*Αυτή η συστηματική ανασκόπηση περιλαμβάνει μια ολοκληρωμένη ανάλυση μελετών που πραγματοποιήθηκαν σε κοινοτικά περιβάλλοντα. Η ανασκόπηση επικεντρώθηκε σε μελέτες που δημοσιεύθηκαν από το 1994 έως το 2009 για τον προσδιορισμό του σημειακού επιπολασμού της πάθησης και από το 2003 έως το 2008 για την αξιολόγηση του επιπολασμού της περιόδου.

**Το ηλικιακό εύρος των συμμετεχόντων στις μελέτες που συμπεριλήφθηκαν στην ανάλυση επιπολασμού διέφερε ευρέως. Εκτείνεται από 55 έως 106 έτη, με ειδικές μελέτες που επικεντρώνονται σε διαφορετικά ηλικιακά όρια: ≥ 59 ετών, ≥ 64 ετών, ≥ 65 ετών (σε δύο ξεχωριστές μελέτες), 70 έως 91 ετών και ≥ 70 ετών (επίσης σε δύο μελέτες). Αυτές οι μελέτες, αναπόσπαστο μέρος της μετα-ανάλυσης, δημοσιεύθηκαν για μια εκτεταμένη περίοδο, από το 1995 έως το 2013.

***Ενσωματωμένα δεδομένα επιπολασμού τυποποιημένα για την ηλικία, που προέκυψαν από μετα-ανάλυση 75 μελετών. Αυτές οι μελέτες, που αναφέρουν τον επιπολασμό της άνοιας AD, διεξήχθησαν σε διάστημα 16 ετών, από το 2001 έως το 2017. Αυτή η εκτεταμένη συλλογή δεδομένων και ανάλυση προσφέρει μια λεπτομερή επισκόπηση του επιπολασμού της άνοιας AD σε διαφορετικές ηλικιακές ομάδες και με την πάροδο του χρόνου, συμβάλλοντας σημαντικά για την κατανόησή μας για τον αντίκτυπο της νόσου.

Συνολικά, η επιδημιολογία και ο επιπολασμός της AD υπογραμμίζουν την πάθηση ως μια κλιμακούμενη παγκόσμια ανησυχία για την υγεία, με την ηλικία να είναι ο σημαντικότερος παράγοντας κινδύνου. Τα εκτεταμένα διαθέσιμα ερευνητικά δεδομένα απεικονίζουν μια λεπτομερή εικόνα του επιπολασμού της AD σε διαφορετικές ηλικιακές ομάδες και φύλα, παρέχοντας πολύτιμες πληροφορίες για το σχεδιασμό της δημόσιας υγείας και την κατανομή των πόρων. Καθώς προχωράμε, η κατανόηση αυτών των προτύπων είναι σημαντική για την αντιμετώπιση της αυξανόμενης πρόκλησης που παρουσιάζει η AD σε άτομα, οικογένειες και υποδομές υγειονομικής περίθαλψης παγκοσμίως.

1.3. Συμπτώματα

Σε αυτό το κεφάλαιο γίνεται εμβάθυνση στην εξέλιξη της AD, που χαρακτηρίζεται από ένα φάσμα συμπτωμάτων που εξελίσσονται στα πρώιμα, μεσαία και όψιμα στάδια της. Ξεκινά περιγράφοντας τις λεπτές αλλά αισθητές γνωστικές και συμπεριφορικές αλλαγές στα πρώιμα στάδια της AD, όπου τα άτομα αντιμετωπίζουν προκλήσεις μνήμης, δυσκολίες επικοινωνίας και μικρές αλλαγές στη διάθεση, τη ψυχολογία και την προσωπικότητα[18]. Καθώς η ασθένεια εξελίσσεται στα μεσαία της στάδια, αυτά τα συμπτώματα γίνονται πιο έντονα, επηρεάζοντας την ικανότητα του ατόμου να εκτελεί καθημερινές εργασίες, οδηγώντας σε αυξημένο αποπροσανατολισμό και απαιτώντας μεγαλύτερη φροντίδα και υποστήριξη. Στα τελικά στάδια της AD, τα άτομα βιώνουν βαθιά γνωστική και σωματική εξασθένηση, απαιτώντας πλήρη εξάρτηση από τον φροντιστή. Το κεφάλαιο διερευνά επίσης την εξέλιξη της ατροφίας του εγκεφάλου που σχετίζεται με την AD, τονίζοντας τη χωρική κατανομή της παθολογίας tau και την επίδρασή της στη γνωστική και λειτουργική εξασθένηση. Οι πρόοδοι στις τεχνολογίες απεικόνισης έχουν φωτίσει την ευρεία κατανομή των νευροϊνιδιακών μπερδεμάτων (Neurofibrillary Tangles - NFT) σε διάφορες περιοχές του εγκεφάλου, αμφισβητώντας προηγούμενες υποθέσεις σχετικά με την εξέλιξη της νόσου. Καθώς η AD προχωρά, η ατροφία επεκτείνεται σε κρίσιμες περιοχές του εγκεφάλου, όπως ο ιππόκαμπος [19], επηρεάζοντας σημαντικά τις γνωστικές, αισθητηριακές και συναισθηματικές ικανότητες. Στα τελευταία στάδια, η συμμετοχή της παρεγκεφαλίδας υπογραμμίζει την παγκόσμια φύση των νευροεκφυλιστικών διεργασιών της AD. Αυτό το κεφάλαιο συνθέτει τα ερευνητικά ευρήματα σχετικά με την εξέλιξη των συμπτωμάτων και την ατροφία του εγκεφάλου στη AD, παρέχοντας πληροφορίες για τον πολύπλοκο αντίκτυπο της νόσου στον εγκέφαλο και τη σημασία της έγκαιρης διάγνωσης και προσαρμοσμένων στρατηγικών φροντίδας για τη βελτίωση των αποτελεσμάτων των ασθενών και την υποστήριξη των φροντιστών.

1.3.1. Συμπτώματα κατά στάδια

Η AD εξελίσσεται σε διάφορα στάδια, καθένα από τα οποία χαρακτηρίζεται από διακριτά συμπτώματα που επηρεάζουν τις γνωστικές λειτουργίες, τη συμπεριφορά και τις σωματικές ικανότητες, απαιτώντας διαφορετικά επίπεδα φροντίδας και παρέμβασης.

Στα αρχικά στάδια της AD, τα άτομα συχνά αντιμετωπίζουν λεπτές αλλά αξιοσημείωτες αλλαγές στη μνήμη και τη γνωστική λειτουργία. Αυτές οι αλλαγές εκδηλώνονται ως δυσκολίες στην ανάκληση πρόσφατων γεγονότων, που οδηγούν σε επαναλαμβανόμενες ερωτήσεις και αυξημένη εξάρτηση από βοηθήματα μνήμης. Οι προκλήσεις στην εκτέλεση γνωστών εργασιών, στην αποτελεσματική χρήση της γλώσσας και στην επικοινωνία είναι κοινές, με τα άτομα να δυσκολεύονται να βρουν τις σωστές λέξεις και να βιώνουν μειωμένο λεξιλόγιο. Τα συμπτώματα περιλαμβάνουν επίσης λανθασμένη τοποθέτηση αντικειμένων, αποπροσανατολισμό σε οικεία περιβάλλοντα και προβλήματα με τη διαχείριση πολύπλοκων εργασιών και την παρακολούθηση του χρόνου. Αν και αυτοί οι πρώιμοι δείκτες μπορεί να μην διαταράσσουν σημαντικά την καθημερινή ζωή, υπογραμμίζουν την ανάγκη για ιατρική αξιολόγηση και τη δυνατότητα έγκαιρης παρέμβασης, καθοριστικής σημασίας για την αποτελεσματική διαχείριση της εξέλιξης της νόσου[20]. Αλλαγές διάθεσης, όπως ευερεθιστότητα, άγχος ή κατάθλιψη και αλλαγές προσωπικότητας όπως απόσυρση ή απάθεια, συχνά συνοδεύουν αυτές τις γνωστικές αλλαγές. Η

έγκαιρη διάγνωση είναι το κλειδί για την καλύτερη διαχείριση της νόσου και την πρόσβαση σε υπηρεσίες θεραπείας και υποστήριξης[21].

Η Ήπια Γνωσιακή Εξασθένηση (MCI) χρησιμεύει ως ενδιάμεση φάση μεταξύ της φυσιολογικής γήρανσης και των πιο σοβαρών μορφών άνοιας, συμπεριλαμβανομένης της AD. Ορίζεται από ελαφρές αλλά μετρήσιμες αλλαγές στη μνήμη, τη γλώσσα και τις εκτελεστικές λειτουργίες πέρα από τις τυπικές αλλαγές που σχετίζονται με την ηλικία, με τα άτομα γενικά να διατηρούν την ανεξαρτησία της καθημερινής δραστηριότητας. Ενώ η MCI αναγνωρίζεται ως παράγοντας κινδύνου για AD, με πολλούς να εξελίσσονται σε άνοια, περιλαμβάνει αρκετούς υποτύπους και απαιτεί τακτική παρακολούθηση για πιθανή εξέλιξη της νόσου. Η έγκαιρη ανίχνευση και διαχείριση της MCI μπορεί να επηρεάσει σημαντικά τα αποτελέσματα[23].

Καθώς η AD προχωρά στο μεσαίο της στάδιο, τα άτομα αντιμετωπίζουν ένα φάσμα προκλήσεων. Τα ελλείμματα μνήμης βαθαίνουν, επηρεάζοντας βασικές προσωπικές πληροφορίες και τα εμπόδια επικοινωνίας εντείνονται. Ο αποπροσανατολισμός και οι δυσκολίες στη διαχείριση της προσωπικής φροντίδας γίνονται πιο συχνές, απαιτώντας πρόσθετη υποστήριξη. Οι αλλαγές συμπεριφοράς, όπως η διέγερση, η επιθετικότητα και η συναισθηματική αστάθεια, εμφανίζονται παράλληλα με τις γνωστικές βλάβες που εμποδίζουν την κρίση και τη λογική. Αναπτύσσονται πιο σοβαρά ζητήματα γλώσσας και επικοινωνίας, συμβάλλοντας στην απογοήτευση. Η περιπλάνηση, το φαινόμενο της «δύσης του ήλιου» και η ακράτεια ούρων θέτουν σημαντικές προκλήσεις ασφάλειας και φροντίδας[24][25][26][27]. Αυτές οι νευροψυχιατρικές και συμπεριφορικές αλλαγές υπογραμμίζουν την πολυπλοκότητα της AD μεσαίου σταδίου, τονίζοντας την ανάγκη για προσαρμοσμένες στρατηγικές φροντίδας και ισχυρά συστήματα υποστήριξης για τα άτομα με Αλτσχάιμερ και τους φροντιστές τους[26].

Στα τελικά στάδια της AD, η βαθιά γνωστική και σωματική εξασθένηση οδηγεί σε πλήρη εξάρτηση από τον φροντιστή. Οι ικανότητες λεκτικής επικοινωνίας μειώνονται δραστικά και η απάθεια και η εξάντληση κυριαρχούν. Η μυϊκή μάζα και η κινητικότητα επιδεινώνονται περαιτέρω, με αποτέλεσμα συχνά άτομα κατάκοιτα που χρειάζονται ολοκληρωμένη φροντίδα. Συχνά εμφανίζονται επιπλοκές όπως λοιμώξεις ή πνευμονία από εισρόφηση, που συμβάλλουν στη θνησιμότητα[26]. Περιστασιακά, η «παράδοση διαύγεια» μπορεί να προσφέρει μια σύντομη περίοδο διανοητικής διαύγειας και αναγνώρισης, προσφέροντας άνεση στους φροντιστές και την οικογένεια στις τελευταίες στιγμές της νόσου[28].

Σε κάθε στάδιο της AD, τα εξελισσόμενα συμπτώματα υπογραμμίζουν την πολυπλοκότητα και τον εκτεταμένο αντίκτυπο της νόσου, υπογραμμίζοντας τη σημασία της έγκαιρης διάγνωσης, της συνεχούς φροντίδας και της ανάπτυξης αποτελεσματικών στρατηγικών θεραπείας για τη βελτίωση των αποτελεσμάτων των ασθενών και την υποστήριξη των φροντιστών.

1.3.2. Η ατροφία του εγκεφάλου και η εξέλιξή της

Η AD χαρακτηρίζεται από προοδευτική ατροφία του εγκεφάλου, χαρακτηριστικό αυτής της νευροεκφυλιστικής κατάστασης που επηρεάζει ποικίλα διαφορετικές περιοχές του εγκεφάλου καθώς εξελίσσεται η ασθένεια. Οι πρόσφατες εξελίξεις στις τεχνολογίες τρισδιάστατης χαρτογράφησης και απεικόνισης έχουν ρίξει φως στη χωρική κατανομή της παθολογίας tau, τη συσχέτισή της με την ατροφία του εγκεφάλου και τη συνακόλουθη γνωστική και λειτουργική εξασθένηση στα στάδια της νόσου.

Στις πρώιμες φάσεις της AD, η σύγχρονη έρευνα αμφισβητεί την κάποτε επικρατούσα αντίληψη ότι η παθολογία του tau και η επακόλουθη εγκεφαλική

ατροφία εντοπίζονται σε συγκεκριμένες περιοχές. Αντίθετα, είναι εμφανής μια πιο διάχυτη κατανομή των νευροϊνιδιακών μπερδεμάτων (Neurofibrillary Tangles - NFT) σε διάφορες περιοχές, συμπεριλαμβανομένων των ενδορινικών περιοχών, της αμυγδαλής, του ιππόκαμπου και του κροταφοπολικού φλοιού. Αυτό το ευρέως διαδεδομένο φορτίο ταυ υπογραμμίζει μια πολύπλοκη αλληλεπίδραση μεταξύ της συσσώρευσης ταυ και της ατροφίας του εγκεφάλου, που αποκλίνει από τα παραδοσιακά μοντέλα εξέλιξης της AD. Αυτή η φάση αποκαλύπτει σημαντικές αποκλίσεις μεταξύ των αναμενόμενων επιπέδων ατροφίας και της σταδιοποίησης ταυ, υποδηλώνοντας μεταβλητή δυναμική συσσώρευσης ταυ και προκύπτουσα ατροφία σε διαφορετικές περιοχές του εγκεφάλου [29].

Καθώς η AD προχωρά στα μεσαία της στάδια, η ατροφία περιλαμβάνει τη μέση κροταφική έλικα, αναπόσπαστο μέρος για τη γλώσσα, τη μνήμη και την αισθητηριακή ολοκλήρωση, παρουσιάζοντας σημαντική μείωση του όγκου. Η ατροφία εκτείνεται πέρα από τους κροταφικούς λοβούς σε κρίσιμες περιοχές όπως ο ενδορινικός και ο παραιπόκαμπος φλοιός, και άλλες κροταφικές περιοχές συμπεριλαμβανομένης της κάτω και άνω κροταφικής έλικας, του κροταφικού πόλου και της ατρακτοειδούς έλικας. Αργότερα, το ραβδωτό σώμα και ο θάλαμος, παράλληλα με το μεσαίο μετωπιαίο, το πρόσθιο περιφερειακό, το βρεγματικό (κυρίως τη γωνιακή έλικα), τους νησιωτικούς φλοιούς και την ωχρά, αρχίζουν να εμφανίζουν ατροφία. Αυτές οι περιοχές είναι σημαντικές για εκτελεστικές λειτουργίες, προσοχή, επεξεργασία αισθητηριακών πληροφοριών και συναισθηματική ρύθμιση, υποδεικνύοντας μια διευρυνόμενη επίδραση στις γνωστικές, αισθητηριακές και συναισθηματικές ικανότητες του ασθενούς [29].

Στα τελευταία στάδια της νόσου, το εύρος της ατροφίας διευρύνεται περαιτέρω για να συμπεριλάβει την παρεγκεφαλίδα, αμφισβητώντας τη συμβατική πεποίθηση της διατήρησής της στις νευροεκφυλιστικές διεργασίες της AD. Αν και η παρεγκεφαλιδική ατροφία εκδηλώνεται κυρίως στο τελευταίο στάδιο της AD και εξελίσσεται πιο αργά από την εγκεφαλική ατροφία, η εμπλοκή της δείχνει μια περίπλοκη σχέση μεταξύ παρεγκεφαλιδικού και εγκεφαλικού εκφυλισμού. Αυτό μπορεί να οφείλεται σε επιλεκτική ευπάθεια δικτύου, με ορισμένες παρεγκεφαλιδικές περιοχές να παρουσιάζουν μειωμένη πυκνότητα φαιάς ουσίας. Ο ρόλος της παρεγκεφαλίδας στο τελευταίο στάδιο της AD, πιθανώς συνέπεια της εκτεταμένης εγκεφαλικής αποσύνδεσης και της νευρωνικής απώλειας, υπογραμμίζει τη συνολική φύση της νόσου [30].

1.4. Διαγνωστικές Μέθοδοι Και Κριτήρια

Η διαγνωστική διαδικασία για τη AD είναι περιεκτική και περιλαμβάνει διάφορες μεθόδους για την αξιολόγηση της γνωστικής εξασθένησης και τον αποκλεισμό άλλων πιθανών αιτιών. Συνήθως ξεκινά με μια ενδελεχή κλινική αξιολόγηση, η οποία περιλαμβάνει λεπτομερές ιατρικό ιστορικό, φυσική εξέταση και νευρολογική αξιολόγηση. Αυτή η αξιολόγηση εστιάζει στη γνωστική λειτουργία, τη μνήμη, τις ικανότητες σκέψης και τις αλλαγές συμπεριφοράς. Γνωστικά τεστ όπως η εξέταση η Σύντομη Εξέταση Ψυχικής Κατάστασης (MMSE), η Γνωσιακή Αξιολόγηση του Μόντρεαλ (MoCA) ή άλλα νευροψυχολογικά τεστ χρησιμοποιούνται συνήθως για την αξιολόγηση της εξασθένησης της μνήμης. Οι εργαστηριακές εξετάσεις αποτελούν επίσης αναπόσπαστο μέρος της διαγνωστικής διαδικασίας. Διεξάγονται για να αποκλειστούν άλλες πιθανές αιτίες γνωστικής εξασθένησης, όπως διαταραχές του θυρεοειδούς, ανεπάρκειες βιταμινών ή λοιμώξεις. Τεχνικές απεικόνισης εγκεφάλου όπως η Μαγνητική Τομογραφία (MRI) ή η Τομογραφία Εκπομπής Ποζιτρονίων (PET) χρησιμοποιούνται για την απεικόνιση των δομών του εγκεφάλου, την

ανίχνευση της ατροφίας του εγκεφάλου και τον εντοπισμό μη φυσιολογικών εναποθέσεων πρωτεϊνών, συμπεριλαμβανομένων των βήτα-αμυλοειδών πλακών και των συστάδων πρωτεϊνών που σχετίζονται με τουμπουλίνη (tau), που είναι χαρακτηριστικά της νόσου. Επιπλέον, η ανάλυση του εγκεφαλονωτιαίου υγρού (ENY - CSF) για βιοδείκτες όπως το β-αμυλοειδές και οι πρωτεΐνες tau μπορεί να βοηθήσει στην ανίχνευση παθολογικών αλλαγών που σχετίζονται με την AD. Τα διαγνωστικά κριτήρια για την νόσο καθορίζονται από οργανισμούς όπως το Εθνικό Ινστιτούτο για τη Γήρανση και την Ένωση Αλτσχάιμερ (NIA-AA) και τη Διεθνή Ομάδα Εργασίας (IWG). Αυτά τα κριτήρια παρέχουν οδηγίες για κλινικούς ιατρούς και ερευνητές, περιγράφοντας βασικά κλινικά χαρακτηριστικά, βιοδείκτες και υποστηρικτικά στοιχεία που απαιτούνται για τη διάγνωση. Τα κριτήρια NIA-AA οριοθετούν στάδια της AD, που κυμαίνονται από την προκλινική και ήπια γνωστική εξασθένηση έως την άνοια λόγω AD, με συγκεκριμένες οδηγίες για κάθε στάδιο. Τα κριτήρια IWG, από την άλλη πλευρά, δίνουν έμφαση στη χρήση βιοδεικτών και τεχνικών απεικόνισης για την υποστήριξη της διάγνωσης της νόσου, ιδιαίτερα στα αρχικά της στάδια. Επιπλέον, τυπικά διαγνωστικά εγχειρίδια όπως το Διαγνωστικό και Στατιστικό Εγχειρίδιο Ψυχικών Διαταραχών (5η Έκδοση) (DSM-5) και η Διεθνής Ταξινόμηση Νοσημάτων (11η Έκδοση) (ICD-11) παρέχουν τυποποιημένα κριτήρια και ορισμούς για τη διάγνωση νευρογνωστικών διαταραχών, συμπεριλαμβανομένης της AD. Βοηθούν τους κλινικούς γιατρούς να διαγνώσουν και να ταξινομήσουν διάφορους τύπους άνοιας, διασφαλίζοντας μια συνεπή και ακριβή προσέγγιση για τον εντοπισμό της AD μεταξύ άλλων γνωστικών διαταραχών.

1.4.1. Νευροψυχολογικά Τεστ (MMSE & MoCA)

Το MMSE, που αναπτύχθηκε από τους Folstein και McHugh, είναι ένα γνωστικό εργαλείο προσυμπτωματικού ελέγχου που αρχικά σχεδιάστηκε για τη διάκριση μεταξύ οργανικών και λειτουργικών ψυχιατρικών καταστάσεων. Με την αξιολόγηση γνωστικών τομέων όπως ο προσανατολισμός, η μνήμη, η προσοχή, η γλώσσα και η οπτική κατασκευή μέσω μιας σειράς ερωτήσεων, το MMSE, με μέγιστη βαθμολογία 30 πόντους, χορηγείται συνήθως σε 5-10 λεπτά για τη διάγνωση της άνοιας, ιδιαίτερα της πιθανής AD. Παρά τη μέτρια έως υψηλή αξιοπιστία και την ευαισθησία του στις γνωστικές αλλαγές που σχετίζονται με τη φυσιολογική γήρανση και την άνοια, το MMSE αντιμετωπίζει προκλήσεις στον εντοπισμό MCI και στη διαφοροποίηση της ήπιας AD από τη φυσιολογική γήρανση. Οι περιορισμοί του επεκτείνονται στην έλλειψη ευαισθησίας σε προοδευτικές αλλαγές σε σοβαρή AD και πιθανές ασυνέπειες στη χορήγηση και τη βαθμολόγηση, γεγονός που εμποδίζει τη χρησιμότητά του σε διάφορες μελέτες. Επιπλέον, η έμφαση του MMSE στο λεκτικό περιεχόμενο μπορεί να παραβλέπει οπτικοχωρικά ελλείμματα και ήπιες γλωσσικές βλάβες, υποδηλώνοντας το ρόλο του ως προκαταρκτικού εργαλείου ελέγχου για τη γνωστική εξασθένηση, με συστάσεις να ληφθεί υπόψη το μορφωτικό επίπεδο και η γλωσσική ευχέρεια στη διερμηνεία. [31]

Αντίθετα, το MoCA αναδεικνύεται ως ένα σύντομο εργαλείο γνωστικής αξιολόγησης ικανό στην ανίχνευση MCI και ήπιας AD, προσφέροντας μια πιο ολοκληρωμένη αξιολόγηση των γνωστικών τομέων, όπως η εκτελεστική λειτουργία, η βραχυπρόθεσμη μνήμη, οι γλωσσικές δεξιότητες και η οπτικοχωρική επεξεργασία. Αυτό το εύρος κάνει το MoCA πιο ευαίσθητο σε ηπιότερες γνωστικές βλάβες από το MMSE. Η ικανότητά του να παρακολουθεί τη βραχυπρόθεσμη γνωστική εξασθένηση ενισχύει τη χρησιμότητά του στην παρακολούθηση της εξέλιξης της νόσου. Παρά τα πλεονεκτήματά του, το MoCA έχει επίσης περιορισμούς, όπως μια στενότερη εστίαση σε συγκεκριμένους υποτύπους MCI και την ανάγκη για πρόσθετες

διαχρονικές μελέτες για να επιβεβαιωθεί η αποτελεσματικότητά του στην ακριβή καταγραφή της γνωστικής εξασθένησης.[32]

1.4.2. Εξέταση Εγκεφαλονωτιαίου Υγρού (CSF)

Τα τεστ CSF διαδραματίζουν κρίσιμο ρόλο στη διάγνωση της AD, επιτρέποντας την αξιολόγηση συγκεκριμένων βιοδεικτών ενδεικτικών της παθολογίας της νόσου, όπως το αμυλοειδές βήτα πεπτίδιο (Aβ), το ολικό tau (t-tau) και το φωσφορυλιωμένο tau (p-tau). Αυτοί οι βιοδείκτες συλλέγονται μέσω μιας οσφυϊκής παρακέντησης, η οποία συγκεντρώνει υγρό από το κάτω μέρος της σπονδυλικής στήλης για να αντικατοπτρίζει τις βιοχημικές αλλαγές του εγκεφάλου. Η ανάλυση των βιοδεικτών του πυρήνα του CSF, συμπεριλαμβανομένων των Aβ1-42, t-tau και p-tau, προσφέρει υψηλή διαγνωστική αξία, διαγιγνώσκοντας αποτελεσματικά την AD και εντοπίζοντας τα πρώιμα στάδια της σε περιπτώσεις ήπιας γνωστικής εξασθένησης. Τα συγκεκριμένα μοτίβα των βιοδεικτών στο CSF μπορούν να σηματοδοτήσουν την εξέλιξη της νόσου και να βοηθήσουν στη διάκριση της AD από άλλες διαταραχές με παρόμοια συμπτώματα.

Η σύζευξη της ανάλυσης βιοδεικτών CSF με τεχνικές απεικόνισης εγκεφάλου όπως η μαγνητική τομογραφία ή οι σαρώσεις PET ενισχύει σημαντικά τη διαγνωστική ακρίβεια, βελτιώνοντας την ανίχνευση αλλαγών που σχετίζονται με τη νόσο και διαφοροποιώντας την AD από άλλες νευροεκφυλιστικές διαταραχές. Στον τομέα των κλινικών δοκιμών και της ανάπτυξης φαρμάκων, αυτοί οι βιοδείκτες είναι απαραίτητοι για την επιλογή κατάλληλων συμμετεχόντων, που χρησιμεύουν ως δείκτες ασφάλειας και για την αξιολόγηση των επιπτώσεων των φαρμάκων στην παθογένεια της νόσου.

Παρά την κρίσιμη αξία τους, η τυποποίηση των μετρήσεων βιοδεικτών CSF παρουσιάζει προκλήσεις, με διακυμάνσεις στα αναφερόμενα επίπεδα μεταξύ των εργαστηρίων. Προσπάθειες φορέων όπως το Εργαστήριο Κλινικής Νευροχημείας βρίσκονται σε εξέλιξη για την εναρμόνιση αυτών των μετρήσεων. Ενώ η επεμβατική φύση των οσφυονωτιαίων παρακεντήσεων και η απαίτηση για εξειδικευμένο εξοπλισμό και τεχνογνωσία περιορίζουν τη χρήση βιοδεικτών στην καθημερινή κλινική πρακτική, η σημασία τους για την έγκαιρη διάγνωση και την ανάπτυξη αποτελεσματικών θεραπειών AD είναι αδιαμφισβήτητη. [33]

1.4.3. Απεικονίσεις MRI & PET

Η μαγνητική τομογραφία (MRI) είναι μια εξελιγμένη τεχνολογία απεικόνισης που χρησιμοποιεί τις φυσικές μαγνητικές ιδιότητες του σώματος για τη δημιουργία λεπτομερών εικόνων από οποιοδήποτε μέρος του σώματος, με ιδιαίτερη έμφαση στους πυρήνες υδρογόνου (πρωτόνια) λόγω της αφθονίας τους σε νερό και λίπος. Η βασική αρχή της μαγνητικής τομογραφίας περιλαμβάνει την ευθυγράμμιση αυτών των πρωτονίων υδρογόνου, τα οποία συμπεριφέρονται σαν μαγνήτες μικρών ράβδων, μέσα σε ένα ισχυρό μαγνητικό πεδίο που συνήθως δημιουργείται από έναν σαρωτή μαγνητικής τομογραφίας. Αυτή η ένταση πεδίου κυμαίνεται συνήθως μεταξύ 0,5 και 1,5 tesla.

Υπό κανονικές συνθήκες, οι άξονες των πρωτονίων υδρογόνου στο σώμα ευθυγραμμίζονται τυχαία. Όταν υποβάλλονται στο μαγνητικό πεδίο ενός σαρωτή MRI, αυτά τα πρωτόνια ευθυγραμμίζονται ομοιόμορφα, δημιουργώντας ένα μαγνητικό διάνυσμα προσανατολισμένο κατά μήκος του άξονα του σαρωτή. Η προσθήκη ενέργειας με τη μορφή κυμάτων ραδιοσυχνότητας (RF) εκτρέπει αυτό το μαγνητικό διάνυσμα. Η ειδική συχνότητα που απαιτείται για να συντονιστεί με τους πυρήνες του υδρογόνου εξαρτάται από το στοιχείο και την ισχύ του μαγνητικού

πεδίου. Όταν η πηγή RF είναι απενεργοποιημένη, το μαγνητικό διάνυσμα επιστρέφει στην κατάσταση ηρεμίας, εκπέμποντας ένα σήμα που χρησιμοποιείται για τη δημιουργία εικόνων MR. Αυτό το σήμα συλλαμβάνεται από πηνία δέκτη, τα οποία λειτουργούν ως κεραίες γύρω από το μέρος του σώματος που απεικονίζεται και η ένταση αυτού του σήματος σχεδιάζεται σε κλίμακα του γκρι για τη δημιουργία εικόνων διατομής.

Η μοναδική ικανότητα της μαγνητικής τομογραφίας έγκειται στην ικανότητά της να διαφοροποιεί τους ιστούς με βάση τους ρυθμούς χαλάρωσής τους μετά τη μετάδοση παλμών RF. Η χαλάρωση T1 μετρά το χρόνο που απαιτείται για να επιστρέψει το μαγνητικό διάνυσμα στην κατάσταση ηρεμίας, ενώ η χαλάρωση T2 μετρά το χρόνο χαλάρωσης του αξονικού σπιν. Διαφορετικοί ιστοί, όπως το λίπος και το νερό, έχουν διαφορετικούς χρόνους χαλάρωσης, επιτρέποντας την ξεχωριστή αναγνώρισή τους. Για παράδειγμα, μια ακολουθία παλμών «καταστολής λίπους» μπορεί να απομονώσει το σήμα από ανωμαλίες που βρίσκονται μέσα στο λίπος. Η μαγνητική τομογραφία είναι ιδιαίτερα ευαίσθητη στην ανίχνευση ασθενειών, οι οποίες συνήθως εκδηλώνονται ως αύξηση της περιεκτικότητας σε νερό. Ωστόσο, η ερμηνεία της ακριβούς φύσης της παθολογίας απαιτεί προσεκτική ανάλυση των εικόνων από έναν ακτινολόγο.

Η μη επεμβατική φύση της μαγνητικής τομογραφίας και η έλλειψη βιολογικών κινδύνων, καθώς χρησιμοποιεί ακτινοβολία ραδιοσυχνότητας, η οποία δεν καταστρέφει τον ιστό, την καθιστούν προτιμώμενη επιλογή για ιατρική απεικόνιση. Ωστόσο, απαιτείται προσοχή με ασθενείς που έχουν βηματοδότες, μεταλλικά κλιπ ή μεταλλικές βαλβίδες λόγω πιθανής κίνησης εντός του μαγνητικού πεδίου. [34]

Στο πλαίσιο της διάγνωσης της AD, το MRI είναι ανεκτίμητο. Παρέχει εικόνες υψηλής ανάλυσης, υψηλής αντίθεσης της δομής του εγκεφάλου in vivo, ιδιαίτερα αποτελεσματικές σε περιοχές απεικόνισης όπως ο ιππόκαμπος, ο ενδορινικός φλοιός και οι μεγαλύτεροι κροταφικοί λοβοί, όπου εμφανίζονται πρώιμες παθολογικές αλλαγές της AD. Μέτρα που βασίζονται σε μαγνητική τομογραφία κρίσιμα στην έρευνα της νόσου περιλαμβάνουν τον όγκο του ιππόκαμπου, τον όγκο ολόκληρου του εγκεφάλου, τον όγκο/πάχος του ενδορινικού φλοιού και το πάχος του φλοιού ολόκληρου του εγκεφάλου. Αυτές οι μετρήσεις λαμβάνονται μέσω μαγνητικής τομογραφίας υψηλής ανάλυσης σε συνδυασμό με προηγμένες τεχνικές ανάλυσης εικόνας, καθιστώντας τις βασικούς βιοδείκτες απεικόνισης για την κατανόηση της εξέλιξης της νόσου και την αξιολόγηση των επιπτώσεων των πιθανών θεραπειών.

Η διαδικασία ανάλυσης δεδομένων μαγνητικής τομογραφίας σε μελέτες AD είναι εξαιρετικά αυτοματοποιημένη, που περιλαμβάνει βήματα όπως η διόρθωση ανομοιομορφίας έντασης, η κατάτμηση του εγκεφαλικού ιστού και η μέτρηση του πάχους του φλοιού. Τεχνικές όπως ο αλγόριθμος N3 και το Στερεοταξικό Περιβάλλον Κανονικοποιημένης Έντασης για Ταξινόμηση Ιστών (INSECT) χρησιμοποιούνται για την ακριβή ταξινόμηση του εγκεφαλικού ιστού. Η κατάτμηση του εγκεφάλου σε φαιά ουσία, λευκή ουσία, εγκεφαλονωτιαίο υγρό και υποτύπους βλαβών, και τεχνικές όπως η Αυτοματοποιημένη Μη Γραμμική Τεχνική Αντιστοίχισης Εικόνας και Ανατομικής Επισήμανσης (ANIMAL) και η Περιορισμένη Λαπλασιανή Ανατομική Τμηματοποίηση (CLASP), διευκολύνουν την ακριβή ανατομική επισήμανση και τη μέτρηση του πάχους του φλοιού.

Ο ρόλος της μαγνητικής τομογραφίας στην έρευνα της νόσου επεκτείνεται σε μεγάλες πολυτοπικές μελέτες, συμπεριλαμβανομένων ατόμων με AD, MCI και υγιείς. Η εναρμόνιση των πρωτοκόλλων απόκτησης εικόνων και η ανάπτυξη μιας βάσης δεδομένων απεικόνισης είναι σημαντική για τη διεξαγωγή μεγάλης κλίμακας,

πολυκεντρικής έρευνας AD. Οι μετρήσεις που βασίζονται σε μαγνητική τομογραφία συμβάλλουν σημαντικά στην ανακάλυψη βιοδεικτών και σε συλλογικές προσπάθειες όπως η Πρωτοβουλία Νευροαπεικόνισης για τη Νόσο του Αλτσχάιμερ (ADNI), ενισχύοντας την κατανόησή μας και βοηθώντας στην ανάπτυξη διαγνωστικών και θεραπευτικών στρατηγικών. [35]

Με βάση τη συζήτηση της μαγνητικής τομογραφίας στη διάγνωση της νόσου, το PET είναι ένα άλλο κρίσιμο εργαλείο απεικόνισης που παρέχει πληροφορίες για τη λειτουργία του εγκεφάλου και τους συγκεκριμένους βιοδείκτες που σχετίζονται με την AD.

Το PET λειτουργεί μετρώντας φυσιολογικές λειτουργίες όπως η ροή του αίματος, ο μεταβολισμός, η δραστηριότητα των νευροδιαβιβαστών και η διανομή ραδιοσημασμένων φαρμάκων. Οι ποσοτικές αναλύσεις του επιτρέπουν την παρακολούθηση των σχετικών αλλαγών με την πάροδο του χρόνου, είτε καθώς εξελίσσεται μια ασθένεια είτε ως απόκριση σε ένα συγκεκριμένο ερέθισμα. Η τεχνική περιλαμβάνει την έγχυση μιας μικρής ποσότητας ραδιενεργού ιχνηθέτη, συνήθως επισημασμένου με ισότοπα όπως οξυγόνο-15, φθόριο-18, άνθρακας-11 ή άζωτο-13, σε μια περιφερική φλέβα. Αυτός ο ιχνηθέτης συσσωρεύεται σε διάφορα μέρη του σώματος με βάση τη μεταβολική δραστηριότητα. Για παράδειγμα, το ραδιοσημασμένο ανάλογο γλυκόζης 18-φθοροδεοξυγλυκόζη (FDG) χρησιμοποιείται για τη μέτρηση των ποσοστών κατανάλωσης γλυκόζης, το οποίο είναι ιδιαίτερα χρήσιμο στη διάκριση μεταξύ καλοήθων και κακοηθών όγκων. Οι σαρώσεις PET, οι οποίες διαρκούν από 10 έως 40 λεπτά, είναι ανώδυνες και δεν απαιτούν την αφαίρεση των ρούχων του ασθενούς. [36]

Στο πλαίσιο της AD, το PET είναι πολύτιμο για την αξιολόγηση της λειτουργίας του εγκεφάλου και τον εντοπισμό συγκεκριμένων βιοδεικτών που σχετίζονται με τη νόσο. Το FDG-PET, για παράδειγμα, αποκαλύπτει πρότυπα εγκεφαλικού μεταβολισμού γλυκόζης, τα οποία είναι διακριτά σε άτομα με AD. Οι αλλαγές σε αυτούς τους μεταβολικούς ρυθμούς μπορεί ακόμη και να προηγούνται των κλινικών συμπτωμάτων, βοηθώντας στην έγκαιρη ανίχνευση. Η απεικόνιση PET μπορεί επίσης να παρακολουθεί την εναπόθεση του Α-αμυλοειδούς στον εγκέφαλο, χαρακτηριστικό της AD, βοηθώντας στη διαφοροποίηση της AD από άλλες μορφές άνοιας. Αυτό καθιστά το PET ένα κρίσιμο εργαλείο τόσο στη διάγνωση όσο και στην κατανόηση της εξέλιξης της AD. [37]

Αντίθετα, η μαγνητική τομογραφία παρέχει εικόνες υψηλής ανάλυσης, υψηλής αντίθεσης της δομής του εγκεφάλου in vivo. Είναι ιδιαίτερα αποτελεσματικό στην απεικόνιση αλλαγών του εγκεφάλου που σχετίζονται με AD, όπως στον ιππόκαμπο, τον ενδορινικό φλοιό και τους μεγαλύτερους κροταφικούς λοβούς. Σε αντίθεση με το PET, η μαγνητική τομογραφία δεν περιλαμβάνει ionτίζουσα ακτινοβολία και είναι κατάλληλη για επαναλαμβανόμενη χρήση. Μέτρα που βασίζονται σε μαγνητική τομογραφία μεγάλης σημασίας σε μελέτες AD περιλαμβάνουν όγκο ιππόκαμπου, όγκο ολόκληρου του εγκεφάλου, όγκο/πάχος του ενδορινικού φλοιού και το πάχος του φλοιού ολόκληρου του εγκεφάλου. Αυτές οι μετρήσεις, που λαμβάνονται μέσω προηγμένων τεχνικών ανάλυσης εικόνας, χρησιμεύουν ως βασικοί βιοδείκτες, παρέχοντας πληροφορίες για την εξέλιξη της νόσου και τον αντίκτυπο των πιθανών θεραπειών στον εγκέφαλο.

Μαζί, το PET και η μαγνητική τομογραφία προσφέρουν συμπληρωματικές πληροφορίες για την AD. Ενώ το PET εστιάζει σε λειτουργικές πτυχές και στον προσδιορισμό βιοδεικτών, η μαγνητική τομογραφία παρέχει λεπτομερείς δομικές πληροφορίες. Η συνδυασμένη χρήση τους ενισχύει την ακρίβεια και την πληρότητα της διάγνωσης της AD και βοηθά στην παρακολούθηση της αποτελεσματικότητας

των θεραπευτικών παρεμβάσεων, καθιστώντας τα απαραίτητα εργαλεία στη συνεχιζόμενη μάχη κατά της νόσου του Αλτσχάιμερ.

1.5. Τεχνικές Απεικόνισης MRI & Έρευνα Στη Διάγνωση Της AD

Η μαγνητική τομογραφία είναι απαραίτητη στη διάγνωση και την έρευνα της AD και της MCI. Η μαγνητική τομογραφία προσφέρει μια σειρά τεχνικών που παρέχουν λεπτομερείς πληροφορίες για τη δομή και τη λειτουργία του εγκεφάλου, σημαντικές για την κατανόηση της παθοφυσιολογίας αυτών των καταστάσεων.

Η δομική μαγνητική τομογραφία είναι συχνά το σημείο εκκίνησης στην απεικόνιση AD, αποκαλύπτοντας τη χαρακτηριστική εγκεφαλική ατροφία που σχετίζεται με τη νόσο. Παρέχει εικόνες υψηλής ανάλυσης που επιτρέπουν στους κλινικούς ιατρούς και τους ερευνητές να παρατηρούν συρρίκνωση σε συγκεκριμένες περιοχές του εγκεφάλου, ειδικά στις δομές του έσω κροταφικού λοβού, όπως ο υπόκαμπος και ο ενδορινικός φλοιός. Αυτές οι αλλαγές στον όγκο του εγκεφάλου βοηθούν στη διάκριση της AD από άλλους τύπους άνοιας και είναι προγνωστικές για την εξέλιξη της νόσου. [38]

Η απεικόνιση τανυστή διάχυσης (DTI) είναι μια άλλη εξελιγμένη τεχνική MRI που διερευνά τη μικροδομική ακεραιότητα της λευκής ουσίας του εγκεφάλου. Το DTI μετρά τη διάχυση των μορίων του νερού κατά μήκος των αξόνων, παρέχοντας πληροφορίες για την κατευθυντικότητα και την ακεραιότητα των οδών της λευκής ουσίας. Αυτό είναι ιδιαίτερα σημαντικό στην AD, όπου το DTI μπορεί να ανιχνεύσει ανεπαίσθητες αλλαγές στη δομή του εγκεφαλικού ιστού προτού γίνουν εμφανείς σε δομικές σαρώσεις MRI. Εξετάζοντας παραμέτρους όπως η κλασματική ανισοτροπία, το DTI βοηθά στον εντοπισμό περιοχών όπου η καλωδίωση του εγκεφάλου μπορεί να διακυβευτεί, γεγονός που είναι ενδεικτικό των πρώιμων διεργασιών της νόσου στην AD. [39]

Η σήμανση αρτηριακού σπιν (ASL) παρέχει μια μη επεμβατική μέθοδο για τη μέτρηση της εγκεφαλικής ροής αίματος (CBF). Το ASL επισημαίνει το νερό του αίματος με μαγνητικά πεδία, επιτρέποντας την απεικόνιση της αιμάτωσης χωρίς την ανάγκη σκιαγραφικών. Οι αλλαγές στη ροή του αίματος μπορεί να υποδεικνύουν περιοχές του εγκεφάλου που επηρεάζονται από την παθολογία της AD πριν γίνουν ορατές οι δομικές αλλαγές. Το ASL είναι ιδιαίτερα χρήσιμο για την παρακολούθηση της εξέλιξης της AD και την αξιολόγηση των απαντήσεων στις θεραπευτικές παρεμβάσεις. [40]

Η Φασματοσκοπία Μαγνητικού Συντονισμού (MRS) επιτρέπει τη μη επεμβατική μελέτη των μεταβολιτών του εγκεφάλου, προσφέροντας ένα «χημικό στιγμιότυπο» της βιοχημείας του εγκεφάλου. Το MRS μπορεί να ανιχνεύσει αλλοιώσεις σε μεταβολικές ενώσεις όπως ο ασπαρτικός Ν-ακετυλεστεράς, δείκτης για την υγεία των νευρώνων και η μυο-ινοσιτόλη, που μπορεί να αντανακλούν τη νευρογλοιακή δραστηριότητα που σχετίζεται με την παθολογία της AD. Αυτά τα επίπεδα μεταβολιτών μπορούν να παρέχουν ενδείξεις σχετικά με τις υποκείμενες βιοχημικές αλλαγές στην AD και την MCI, όπως οξειδωτικό στρες ή διαταραχές του ενεργειακού μεταβολισμού. [41]

Η λειτουργική απεικόνιση μαγνητικού συντονισμού (fMRI) αξιοποιεί την αντίθεση που εξαρτάται από το επίπεδο οξυγόνου του αίματος (BOLD) για να χαρτογραφήσει τα μοτίβα νευρικής δραστηριότητας στον εγκέφαλο. Παρατηρώντας αλλαγές στη ροή του αίματος ως απόκριση σε γνωστικές εργασίες ή σε κατάσταση ηρεμίας, η fMRI μπορεί να εντοπίσει λειτουργικές αλλοιώσεις στα νευρωνικά δίκτυα που είναι συμπτωματικές της AD. Αυτές οι αλλαγές μπορεί να εκδηλωθούν ως μειωμένη δραστηριότητα σε περιοχές που συνήθως εμπλέκονται κατά τη διάρκεια της

μνήμης ή των γνωστικών εργασιών, αντανακλώντας τη λειτουργική επίδραση της AD στον εγκέφαλο. [42]

Οι προηγμένες τεχνικές μαγνητικής τομογραφίας προσφέρουν ολοκληρωμένες γνώσεις σχετικά με τις δομικές και λειτουργικές αλλαγές του εγκεφάλου σε AD και MCI. Δεν βοηθούν μόνο στη διάγνωση αλλά επιτρέπουν επίσης την παρακολούθηση της εξέλιξης της νόσου και την αξιολόγηση της αποτελεσματικότητας της θεραπείας. Ωστόσο, η συνήθης κλινική χρήση προηγμένων μεθόδων MRI πέρα από την παραδοσιακή δομική απεικόνιση είναι περιορισμένη. Ενώ η δομική μαγνητική τομογραφία χρησιμοποιείται συνήθως σε κλινικά περιβάλλοντα, τεχνικές όπως DTI, ASL, MRS και fMRI χρησιμοποιούνται κυρίως στην έρευνα λόγω της πολυπλοκότητάς τους και της ανάγκης για εξειδικευμένη ανάλυση. Αυτές οι τεχνικές περιλαμβάνουν μια διαδικασία πολλαπλών σταδίων που περιλαμβάνει διόρθωση για ανωμαλίες σήματος, τμηματοποίηση του εγκεφάλου σε διαφορετικούς τύπους ιστών και μέτρηση περιοχών ενδιαφέροντος. Προηγμένοι αλγόριθμοι και υπολογιστικές μέθοδοι υποστηρίζουν αυτήν την ανάλυση, επιτρέποντας την ακριβή ταξινόμηση του εγκεφαλικού ιστού και τον εντοπισμό παθολογικών αλλαγών. Η συνεχής ανάπτυξη και τελειοποίηση αυτών των τρόπων μαγνητικής τομογραφίας είναι τεράστιας σημασίας για την ενίσχυση της κατανόησής μας για την AD και την MCI. Καθώς η πρόοδος της τεχνολογίας και οι μεθοδολογίες βελτιώνονται, αυτές οι τεχνικές απεικόνισης υπόσχονται να ενσωματωθούν σε συνήθη διαγνωστικά κριτήρια και να προσφέρουν νέες οδούς για την ανάπτυξη στοχευμένων θεραπειών για την AD και την MCI. Οι δυνατότητές τους στη λεπτομερή απεικόνιση και τη λεπτομερή ανάλυση της δομής και της λειτουργίας του εγκεφάλου είναι ανεκτίμητες για την αποκάλυψη της πολυπλοκότητας αυτών των νευροεκφυλιστικών ασθενειών.

Η βαθιά μάθηση, ένα υποσύνολο της μηχανικής μάθησης που χαρακτηρίζεται από στρώματα νευρωνικών δικτύων, είναι εξαιρετικά κατάλληλη για να διακρίνει μοτίβα και χαρακτηριστικά σε μεγάλα και πολύπλοκα σύνολα δεδομένων που συχνά είναι ανεπαίσθητα από την ανθρώπινη ανάλυση. Όταν εφαρμόζονται στα πλούσια δεδομένα που αποκτώνται από μαγνητικές τομογραφίες, οι αλγόριθμοι βαθιάς μάθησης έχουν τη δυνατότητα να φέρουν επανάσταση στον τρόπο με τον οποίο προσεγγίζουμε την έρευνα και τη διάγνωση της AD. Μπορούν να αυτοματοποιήσουν τη διαδικασία αναγνώρισης βιοδεικτών, να διευκολύνουν την κατάτμηση των εικόνων του εγκεφάλου, να ενισχύσουν την ακρίβεια της ανίχνευσης βλαβών και ενδεχομένως να αποκαλύψουν νέες γνώσεις σχετικά με τα νευρικά θεμέλια της AD. [43]

Αξιοποιώντας τη βαθιά μάθηση, οι ερευνητές και οι κλινικοί γιατροί μπορούν να επεξεργάζονται δεδομένα μαγνητικής τομογραφίας με μεγαλύτερη ακρίβεια και με ταχύτητες που δεν είναι εφικτές με τη μη αυτόματη ανάλυση. Αυτό όχι μόνο επιταχύνει τη διαγνωστική διαδικασία αλλά επίσης ανοίγει νέους δρόμους για εξατομικευμένες ιατρικές προσεγγίσεις στη θεραπεία και διαχείριση της νόσου, προσαρμόζοντας τις παρεμβάσεις σε μεμονωμένα πρότυπα νευρικών αλλαγών. Έτσι, η ενσωμάτωση της βαθιάς μάθησης με τις τρέχουσες τεχνικές μαγνητικής τομογραφίας βρίσκεται στην πρώτη γραμμή της προόδου της έρευνας για την AD και της φροντίδας των ασθενών.

2. Βαθιά Μάθηση

Καθώς γίνεται η μετάβαση προς στη σφαίρα της βαθιάς μάθησης, στα τεχνητά νευρωνικά δίκτυα και στις βαθιές επιπτώσεις τους στην ιατρική διαγνωστική και έρευνα, ξεκινάει ένα νέο κεφάλαιο στη μάχη κατά του Αλτσχάιμερ. Η εξερεύνηση των βαθιών νευρωνικών δικτύων και οι συγκεκριμένες τεχνικές των MLP, RNN και CNN παρέχουν μια ματιά στο μέλλον της έρευνας AD, όπου δεδομένα και αλγόριθμοι συγκλίνουν για να προσφέρουν ελπίδα και καινοτόμες λύσεις.

Στη συνέχεια, πραγματοποιείτε ανάλυση της αρχιτεκτονικής των CNN, που εκτείνεται από το επίπεδο εισόδου έως τα επίπεδα συνέλιξης, συγκέντρωσης, πλήρως συνδεδεμένου και εξόδου, είναι σχολαστικά αποσυσκευασμένη. Κάθε συστατικό εξετάζεται για το ρόλο του στην επεξεργασία και την ερμηνεία των τεράστιων αποθηκών δεδομένων που χαρακτηρίζουν τη σύγχρονη έρευνα, με ιδιαίτερη έμφαση στις λειτουργίες ενεργοποίησης όπως το ReLU και τις παραλλαγές του που χρησιμοποιούν ως η καρδιά αυτών των πολύπλοκων υπολογιστικών μοντέλων.

Αυτό το θεωρητικό υπόβαθρο χρησιμεύει έτσι ως έναυσμα, εισάγοντας τις βασικές έννοιες και θέτοντας τις βάσεις για τις εις βάθος αναλύσεις που ακολουθούν. Θέτει τον αναγνώστη να εκτιμήσει πλήρως τις αποχρώσεις της νόσου και τις μεταμορφωτικές δυνατότητες της βαθιάς μάθησης.

2.1.Εισαγωγή στη Βαθιά Μάθηση

Η βαθιά μάθηση οδήγησε σε μια αλλαγή παραδείγματος στην επεξεργασία δεδομένων, απομακρύνοντας τις παραδοσιακές τεχνικές μηχανικής μάθησης που εξαρτιόνταν σε μεγάλο βαθμό από τη μη αυτόματη εξαγωγή χαρακτηριστικών. Αυτή η πρόοδος ευδοκμεί στην ικανότητά της για εκμάθηση αναπαράστασης, προσδιορίζοντας αυτόνομα τα απαραίτητα χαρακτηριστικά για εργασίες όπως η ανίχνευση ή η ταξινόμηση από ακατέργαστα δεδομένα. Κεντρική θέση στη βαθιά μάθηση είναι τα νευρωνικά δίκτυα με πολλαπλά επίπεδα που δημιουργούν περίπλοκες αναπαραστάσεις από απλές, μη γραμμικές μονάδες, μετατρέποντας τα δεδομένα εισόδου μέσω διαδοχικών επιπέδων σε αφηρημένες μορφές. Στην αναγνώριση εικόνας, για παράδειγμα, ενώ τα αρχικά στρώματα μπορεί να αναγνωρίζουν άκρες και μοτίβα, τα βαθύτερα στρώματα συνθέτουν αυτά τα στοιχεία για να αναγνωρίσουν πολύπλοκα αντικείμενα.

Αυτή η πολυεπίπεδη μεθοδολογία χαρακτηριστικών εκμάθησης διακρίνει εγγενώς τη βαθιά μάθηση, αποφεύγοντας την ανάγκη για χειροκίνητο σχεδιασμό χαρακτηριστικών και επιτρέποντας την ανακάλυψη πολύπλοκων δομών δεδομένων. Η ευελιξία του έχει δει εφαρμογές σε διάφορους τομείς, όπως η αναγνώριση εικόνας και ομιλίας, η ανακάλυψη φαρμάκων και οι εργασίες επεξεργασίας φυσικής γλώσσας, όπως η ανάλυση συναισθημάτων και η μετάφραση.

Η εκπαίδευση αυτών των μοντέλων συνήθως χρησιμοποιεί εποπτευόμενη μάθηση, αξιοποίηση μεγάλων συνόλων δεδομένων για τη βελτίωση των παραμέτρων του νευρωνικού δικτύου, ενισχύοντας την ακρίβεια του μοντέλου μέσω τεχνικών βελτιστοποίησης, όπως η στοχαστική κλίση. Η ικανότητα του μοντέλου να γενικεύει, ή να αποδίδει καλά σε αόρατα δεδομένα, αποτελεί κρίσιμο μέτρο της επιτυχίας του.

Η μετασχηματιστική δύναμη της βαθιάς μάθησης έγκειται στην ικανότητα αυτόνομης μάθησης, με βαθιές νευρικές αρχιτεκτονικές ικανές να συλλαμβάνουν λεπτές λεπτομέρειες σημαντικές για ακριβή ανάλυση, ενώ είναι ανθεκτικές σε άσχετες παραλλαγές δεδομένων. Στην απεικόνιση μαγνητικής τομογραφίας για έρευνα και διάγνωση AD, η βαθιά μάθηση υπόσχεται την επανάσταση στον τομέα. Μπορεί να εκπαιδευτεί στην ανάλυση των πλούσιων συνόλων δεδομένων που

παρέχονται από διάφορες τεχνικές MRI, εντοπίζοντας σημαντικούς δείκτες AD ή MCI, αναγνωρίζοντας βιοδείκτες, τμηματοποιώντας εικόνες και ακόμη και προβλέποντας την εξέλιξη της νόσου.

Καθώς οι αλγόριθμοι και οι αρχιτεκτονικές βαθιάς μάθησης συνεχίζουν να εξελίσσονται, το ίδιο συμβαίνει και με τις πιθανές εφαρμογές τους, υποσχόμενοι πιο ακριβή διαγνωστικά, εξατομικευμένες στρατηγικές θεραπείας και μια βαθύτερη κατανόηση των νευρικών υποστρωμάτων του AD. Αυτή η ενοποίηση με προηγμένες τεχνικές μαγνητικής τομογραφίας θα μπορούσε να βελτιώσει τις διαγνωστικές και θεραπευτικές προσεγγίσεις, προσφέροντας πληροφορίες για τη νευρική βάση της νόσου. [44]

Η βαθιά μάθηση, που βασίζεται στα Τεχνητά Νευρωνικά Δίκτυα (ANN), αντιπροσωπεύει μια μεταμορφωτική δύναμη στη μηχανική μάθηση. Τα ANN, τα θεμέλια των αλγορίθμων βαθιάς μάθησης, είναι σημαντικά για την ανάλυση της πολυπλοκότητας των δεδομένων υψηλών διαστάσεων με τρόπο παρόμοιο με την ερμηνεία των αισθητηριακών εισροών από τον ανθρώπινο εγκέφαλο. Η διερεύνηση των ANN ρίχνει φως στο πώς η βαθιά μάθηση μεταβαίνει από την ιδέα στην εφαρμογή, προσομοιώνοντας τις γνωστικές λειτουργίες μέσω πολυεπίπεδων δομών και διασυνδεδεμένων ενοτήτων, φωτίζοντας έτσι τους μηχανισμούς πίσω από την ικανότητά του να επαναπροσδιορίζει αναλυτικά καθήκοντα σε διάφορους τομείς, συμπεριλαμβανομένης της έρευνας για τη νόσο του Αλτσχάιμερ.

2.2. Τεχνητά Νευρωνικά Δίκτυα (ANNs)

Τα ANN είναι υπολογιστικά πλαίσια που αντλούν έμπνευση από τις νευρικές δομές του ανθρώπινου εγκεφάλου και βρίσκουν εφαρμογή σε πολλούς κλάδους, συμπεριλαμβανομένων των υπολογιστών, της ιατρικής, της μηχανικής και της οικονομίας. Τα θεμελιώδη δομικά στοιχεία των ANN είναι τεχνητοί νευρώνες ή μονάδες επεξεργασίας, οι οποίες διασυνδέονται σε μια δομή που μοιάζει με ιστό με συνδέσμους που φέρουν συγκεκριμένα βάρη. Αυτά τα βάρη είναι σημαντικά καθώς καθορίζουν την επιρροή ενός νευρώνα σε έναν άλλο σε όλη την ιεραρχία του δικτύου.

Η δομή ενός ANN ορίζεται από την αρχιτεκτονική του, η οποία περιλαμβάνει τον αριθμό των επιπέδων και κόμβων που περιέχει, τη μέθοδο που χρησιμοποιεί για να ενημερώσει τα βάρη σύνδεσης, που είναι η ουσία του μηχανισμού μάθησης του, και τις λειτουργίες ενεργοποίησης που ορίζουν τη λειτουργία εισόδου. Τα σήματα μετασχηματίζονται σε κάθε κόμβο μέσα στα επίπεδα. Τα μοτίβα μάθησης που διέπουν τα ANN εμπίπτουν σε τρεις κύριες κατηγορίες. Αυτές είναι η εποπτευόμενη, η μη εποπτευόμενη και ενισχυτική μάθηση, καθεμία από τις οποίες συνοδεύεται από διαφορετικούς αλγόριθμους εκπαίδευσης προσαρμοσμένους στη συγκεκριμένη λειτουργική λογική τους.

Στην εποπτευόμενη μάθηση, το ANN παραμετροποιείται χρησιμοποιώντας ένα σύνολο δεδομένων εκπαίδευσης που αποτελείται από ζεύγη εισόδου-εξόδου. Η διαδικασία είναι παρόμοια με αυτή μιας εργασίας ταξινόμησης, όπου το ANN λειτουργεί ως ταξινομητής. Εδώ, η επιλογή του τύπου ταξινομητή εξαρτάται από τα ιδιαίτερα πλεονεκτήματα και περιορισμούς που παρουσιάζονται από κάθε ταξινομητή. Η εκπαιδευτική διαδικασία περιλαμβάνει τον καθορισμό των παραδειγμάτων εκπαίδευσης, τη συλλογή και προετοιμασία κατάλληλων δεδομένων για το επιλεγμένο μοντέλο ANN, τη διεξαγωγή της διαδικασίας εκμάθησης και την αξιολόγηση της απόδοσης του ANN με δεδομένα δοκιμής.

Η μη εποπτευόμενη μάθηση αποκλίνει από αυτήν την προσέγγιση παραμετροποιώντας το ANN με βάση αποκλειστικά τα δεδομένα εισόδου παράλληλα

με μια συνάρτηση κόστους που πρέπει να ελαχιστοποιηθεί. Αυτό το παράδειγμα βρίσκει τη χρήση του σε τομείς όπου ο στόχος είναι να διακρίνει τα υποκείμενα μοτίβα ή δομές στα δεδομένα, όπως η στατιστική μοντελοποίηση ή η ομαδοποίηση, χωρίς να βασίζεται σε προεπισημασμένα παραδείγματα. Το ANN μαθαίνει να κατηγοριοποιεί ή να οργανώνει δεδομένα αυτόνομα, χρησιμοποιώντας τεχνικές όπως η ομαδοποίηση ή η χρήση αυτοοργάνωσης χαρτών για να το πετύχει αυτό.

Η ενισχυτική μάθηση διαφέρει στο ότι τα δεδομένα για την εκπαίδευση δεν είναι προκαθορισμένα, αλλά δημιουργούνται μέσω των αλληλεπιδράσεων του ANN με το περιβάλλον του, με πρωταρχικό στόχο τη μεγιστοποίηση των σωρευτικών ανταμοιβών. Σε αυτό το παράδειγμα, το ANN αναλαμβάνει ενέργειες σε ένα περιβάλλον που ενημερώνονται από έναν αλγόριθμο σχεδιασμένο να βελτιστοποιεί την πολιτική που διέπει αυτές τις ενέργειες, μεγιστοποιώντας έτσι την απόδοση. Είναι κατάλληλο για σενάρια που απαιτούν ισορροπία μεταξύ άμεσων και μελλοντικών ανταμοιβών και έχει εφαρμοστεί με επιτυχία σε τομείς όπως ο ρομποτικός έλεγχος, οι τηλεπικοινωνίες και τα παιχνίδια στρατηγικής. [45]

Τα ANN αποτελούνται από τρεις τύπους επιπέδων που είναι το επίπεδο εισόδου, ένα ή περισσότερα κρυφά επίπεδα και το επίπεδο εξόδου. Αυτά τα στρώματα αποτελούνται από μεμονωμένες μονάδες ή κόμβους, οι οποίοι μπορούν να παρομοιαστούν με νευρώνες στον βιολογικό εγκέφαλο.

- Το επίπεδο εισόδου χρησιμεύει ως σημείο εισόδου για δεδομένα στο δίκτυο. Κάθε κόμβος στο επίπεδο εισόδου αντιπροσωπεύει ένα χαρακτηριστικό των δεδομένων εισόδου. Για παράδειγμα, σε ένα δίκτυο σχεδιασμένο για την επεξεργασία εικόνων, κάθε κόμβος εισόδου μπορεί να αντιστοιχεί στην ένταση ενός pixel στην εικόνα.
- Τα κρυφά επίπεδα βρίσκονται μεταξύ των επιπέδων εισόδου και εξόδου και ονομάζονται «κρυφά» επειδή δεν αλληλεπιδρούν άμεσα με τα εξωτερικά δεδομένα. Αντίθετα, επεξεργάζονται τις τιμές που λαμβάνονται από το επίπεδο εισόδου εκτελώντας σταθμισμένους υπολογισμούς και μετασχηματισμούς μέσω συναρτήσεων ενεργοποίησης. Τα κρυφά επίπεδα μπορούν να συλλάβουν και να μοντελοποιήσουν πολύπλοκες σχέσεις στα δεδομένα εφαρμόζοντας αυτούς τους μετασχηματισμούς. Ο αριθμός και το μέγεθος των κρυφών επιπέδων μπορεί να ποικίλλει, επηρεάζοντας σημαντικά την ικανότητα του δικτύου για σύνθετη μοντελοποίηση δεδομένων.
- Το επίπεδο εξόδου είναι το τελικό επίπεδο όπου το δίκτυο παράγει το αποτέλεσμα για τη δεδομένη είσοδο. Σε μια εργασία ταξινόμησης, για παράδειγμα, το επίπεδο εξόδου θα παρέχει μια κατανομή πιθανότητας σε διαφορετικές κλάσεις, υποδεικνύοντας την πιθανότητα τα δεδομένα εισόδου να ανήκουν σε κάθε κλάση.

Οι κόμβοι σε αυτά τα επίπεδα είναι διασυνδεδεμένοι και κάθε σύνδεση έχει ένα σχετικό βάρος που προσαρμόζεται καθώς το ANN μαθαίνει από τα δεδομένα. Ο τρόπος διασύνδεσης αυτών των κόμβων και των επιπέδων καθορίζει την αρχιτεκτονική του δικτύου, η οποία μπορεί να επηρεάσει σε μεγάλο βαθμό την απόδοση και τις δυνατότητές του. [46]

Βασιζόμενοι στα θεμέλια των ANN, τα οποία μιμούνται τη διασυνδεδεμένη δομή του ανθρώπινου εγκεφάλου μέσω ενός δικτύου τεχνητών νευρώνων, μεταβαίνουμε σε μια πιο περίπλοκη και ισχυρή ενσάρκωση αυτών των δικτύων γνωστά ως Βαθιά Νευρωνικά Δίκτυα (DNNs). Τα DNN είναι μια προηγμένη μορφή ANN που χαρακτηρίζεται από τη βαθύτερη αρχιτεκτονική τους, που αποτελείται από πολλαπλά κρυφά επίπεδα μεταξύ των επιπέδων εισόδου και εξόδου. Αυτό το βάθος επιτρέπει στα DNN να μοντελοποιούν πολύ περίπλοκα και αφηρημένα μοτίβα μέσα στα δεδομένα, πολύ πέρα από τις δυνατότητες απλούστερων ANN.

2.3.Βαθιά Νευρωνικά Δίκτυα (DNNs)

Τα βαθιά νευρωνικά δίκτυα επεκτείνουν την αρχή της εκμάθησης αναπαράστασης που βρίσκεται στα ANN σε νέα ύψη, επιτρέποντάς τους να συλλάβουν μια περίπλοκη ιεραρχία χαρακτηριστικών. Όπου τα ANN μπορεί να δυσκολεύονται να προχωρήσουν πέρα από τα σχετικά απλά μοτίβα, τα DNN υπερέχουν, χάρη στα πολλαπλά στρώματα μη γραμμικών μονάδων επεξεργασίας. Κάθε επίπεδο σε ένα DNN μετατρέπει τα δεδομένα εισόδου του σε προοδευτικά πιο αφηρημένες και σύνθετες αναπαραστάσεις, με προηγούμενα επίπεδα να καταγράφουν βασικά χαρακτηριστικά όπως άκρες ή υφές σε δεδομένα εικόνας και βαθύτερα στρώματα που τα συνθέτουν σε έννοιες υψηλού επιπέδου, όπως η αναγνώριση αντικειμένων σε μια σκηνή .

Αυτή η πολυεπίπεδη δομή των DNN τους επιτρέπει να εκτελούν αυτόματα μια εξελιγμένη μορφή μηχανικής χαρακτηριστικών. Μέσω της διαδικασίας μάθησης, τα DNN μπορούν να καθορίσουν ποια χαρακτηριστικά είναι πιο προγνωστικά για μια δεδομένη εργασία, όπως η αναγνώριση ομιλίας ή η μετάφραση κειμένου. Αυτή η αυτοματοποιημένη εξαγωγή χαρακτηριστικών είναι σημαντική για τον χειρισμό των ογκωδών και πολύπλοκων συνόλων δεδομένων που επικρατούν σε πολλές σύγχρονες εργασίες μηχανικής εκμάθησης, όπου ο χειροκίνητος σχεδιασμός χαρακτηριστικών θα ήταν ανέφικτος ή αδύνατος

Η αποτελεσματικότητα των DNN σε ένα ευρύ φάσμα εφαρμογών, από την όραση υπολογιστή έως την επεξεργασία φυσικής γλώσσας, πηγάζει από την ικανότητά τους να μαθαίνουν απευθείας από ακατέργαστα δεδομένα. Χρησιμοποιώντας αλγόριθμους που προσαρμόζουν τις εσωτερικές παραμέτρους επαναληπτικά για την ελαχιστοποίηση των σφαλμάτων πρόβλεψης, τα DNN βελτιώνουν συνεχώς την κατανόησή τους για τα δεδομένα, βελτιώνοντας την ακρίβειά τους με την πάροδο του χρόνου. [47]

2.4.Τεχνικές Βαθιάς Μάθησης

Εμβαθύνοντας στις αποχρώσεις των DNN, συναντάμε πολλές εξειδικευμένες τεχνικές που έχουν αναπτυχθεί για να αξιοποιήσουν τη διακριτική δύναμη αυτών των δικτύων για εργασίες όπως η ταξινόμηση και η πρόβλεψη. Αυτές οι τεχνικές, προσαρμοσμένες για την αντιμετώπιση συγκεκριμένων τύπων δεδομένων και δομών προβλημάτων, περιλαμβάνουν το Perceptron πολλαπλών επιπέδων (MLP), τα επαναλαμβανόμενα νευρωνικά δίκτυα (RNN) και τα συνελκτικά νευρωνικά δίκτυα (CNN), το καθένα με τις παραλλαγές του.

Το MLP, ένας τύπος τεχνητού νευρωνικού δικτύου ανατροφοδότησης, θεωρείται ο ακρογωνιαίος λίθος της βαθιάς μάθησης. Τα πλήρως συνδεδεμένα επίπεδά του λειτουργούν ως υπολογιστική μηχανή, προωθώντας την ικανότητα του δικτύου να λαμβάνει αποφάσεις ή προβλέψεις σχετικά με τα δεδομένα εισόδου. Τα RNN, γνωστά για τις μοναδικές τους δυνατότητες «μνήμης», είναι έμπειρα στην επεξεργασία διαδοχικών δεδομένων, καθιστώντας τα απαραίτητα σε τομείς όπως η επεξεργασία φυσικής γλώσσας και η αναγνώριση ομιλίας. Τέλος, τα CNN έχουν φέρει επανάσταση στον τομέα της όρασης υπολογιστών με την ικανότητά τους να εξάγουν αυτόματα και να μαθαίνουν τα πιο σχετικά χαρακτηριστικά από την οπτική είσοδο χωρίς την ανάγκη χειροκίνητης μηχανικής λειτουργιών.


Καθώς περνάμε από τη γενική κατανόηση των DNN στην εξερεύνηση αυτών των ειδικών τεχνικών, γίνεται σαφές πώς κάθε μέθοδος συμβάλλει μοναδικά στην πρόοδο της βαθιάς μάθησης. Αποδεικνύουν την προσαρμοστικότητα και τη δύναμη της βαθιάς μάθησης, με κάθε τεχνική να ανοίγει νέες πόρτες για καινοτομία και

εφαρμογή σε διάφορους τομείς. Οι επόμενες ενότητες θα εμβαθύνουν στην περίπλοκη λειτουργία καθεμιάς από αυτές τις τεχνικές, ρίχνοντας φως στον τρόπο με τον οποίο μετατρέπουν τα ακατέργαστα δεδομένα σε ευδιάκριτα μοτίβα και πρακτικές ιδέες. [48]

2.4.1. Perceptron Πολλών Επιπέδων (MLP)

Το MLP είναι μια κομβική τεχνική στον τομέα της βαθιάς μάθησης, αντιπροσωπεύοντας μια σημαντική πρόοδο σε σχέση με απλούστερες αρχιτεκτονικές νευρωνικών δικτύων όπως το Νευρωνικό Δίκτυο ενός επιπέδου (SLP). Ως τύπος τεχνητού νευρωνικού δικτύου τροφοδοσίας, το MLP χαρακτηρίζεται από τα πολλαπλά του στρώματα, τα οποία περιλαμβάνουν ένα στρώμα εισόδου, ένα ή περισσότερα κρυφά στρώματα και ένα στρώμα εξόδου. Αυτή η δομή επιτρέπει στα MLP να μοντελοποιούν αποτελεσματικά πολύπλοκες, μη γραμμικές σχέσεις στα δεδομένα, καθιστώντας τα ευέλικτα για ένα ευρύ φάσμα εφαρμογών, συμπεριλαμβανομένων των εργασιών ταξινόμησης και πρόβλεψης.

Στην καρδιά της λειτουργικότητας ενός MLP βρίσκεται η πολυεπίπεδη αρχιτεκτονική του. Το επίπεδο εισόδου λαμβάνει τα προς επεξεργασία δεδομένα, ενώ το επίπεδο εξόδου είναι υπεύθυνο για τη λήψη προβλέψεων ή αποφάσεων με βάση αυτή την είσοδο. Ανάμεσα σε αυτά τα δύο βρίσκονται τα κρυφά επίπεδα, τα οποία είναι οι πραγματικές υπολογιστικές μηχανές του δικτύου. Κάθε νευρώνας σε αυτά τα στρώματα συνδέεται με κάθε νευρώνα στο επόμενο επίπεδο και αυτές οι συνδέσεις ή τα βάρη προσαρμόζονται κατά τη φάση εκπαίδευσης του δικτύου. [49]



Εικόνα 2.1. MLP με δύο κρυφά επίπεδα [50]

Μία από τις πιο κρίσιμες πτυχές του MLP είναι η χρήση της αντίστροφης διάδοσης (back-propagation) ως αλγόριθμου εκμάθησης. Η αντίστροφη διάδοση περιλαμβάνει την επαναληπτική προσαρμογή των βαρών του δικτύου για να ελαχιστοποιηθεί το σφάλμα μεταξύ της προβλεπόμενης εξόδου του δικτύου και της πραγματικής εξόδου. Αυτή η διαδικασία υποστηρίζεται από διάφορες τεχνικές βελτιστοποίησης όπως η Στοχαστική κλίση κατάβασης (SGD) [51] και η Προσαρμοστική Εκτίμηση Ροπής (Adam) [52]. Αυτές οι τεχνικές διασφαλίζουν ότι το MLP μαθαίνει αποτελεσματικά από τα δεδομένα εκπαίδευσης, βελτιώνοντας τα βάρη και τις προκαταλήψεις του για να βελτιώσει την ακρίβεια πρόβλεψης. [51][52][53]

Τα MLP έχουν σχεδιαστεί για να προσεγγίζουν οποιαδήποτε συνεχή λειτουργία, καθιστώντας τα απίστευτα ισχυρά για την επίλυση προβλημάτων που δεν διαχωρίζονται γραμμικά, κάτι που αποτελεί περιορισμό απλούστερων μοντέλων όπως το SLP. Μπορούν να μάθουν μη γραμμικά μοντέλα σε πραγματικό χρόνο ή διαδικτυακά, κάτι που είναι πλεονεκτικό για εργασίες ταξινόμησης, αναγνώρισης, πρόβλεψης και προσέγγισης προτύπων.

Στην πράξη, τα MLP έχουν χρησιμοποιηθεί σε ποικίλες εφαρμογές που κυμαίνονται από τα νανοφωτονικά έως την ιατρική διάγνωση. Για παράδειγμα, στη νανοφωτονική, τα MLP έχουν χρησιμοποιηθεί τόσο για εργασίες μπροστινής μοντελοποίησης όσο και για εργασίες αντίστροφης σχεδίασης. Στη μπροστινή μοντελοποίηση, τα MLP μπορούν να προσεγγίσουν πολύπλοκες φυσικές εξισώσεις, όπως οι εξισώσεις του Maxwell, για να προβλέψουν τα φάσματα σκέδασης των νανοσωματιδίων. Για τον αντίστροφο σχεδιασμό, τα MLP μπορούν να χρησιμοποιηθούν για τον προσδιορισμό της φυσικής δομής υλικών όπως τα νανοσωματίδια του πυρήνα του κελύφους ή οι ενσωματωμένες νανοφωτονικές συσκευές με βάση τις επιθυμητές οπτικές ιδιότητες. [54]


Μια αξιοσημείωτη πρόκληση στη χρήση MLP για αντίστροφη σχεδίαση είναι η μη μοναδικότητα των λύσεων, όπου διαφορετικές δομές μπορούν να αποδώσουν παρόμοιες οπτικές ιδιότητες. Για να αντιμετωπιστεί αυτό, έχουν εισαχθεί διαδοχικά δίκτυα, τα οποία συνδυάζουν ένα προεκπαιδευμένο δίκτυο μοντελοποίησης με ένα αντίστροφο δίκτυο. Αυτή η προσέγγιση διασφαλίζει ότι ο αντίστροφος σχεδιασμός ταιριάζει στενά με τα επιθυμητά κριτήρια, αποδεικνύοντας την προσαρμοστικότητα των MLP στην επίλυση σύνθετων προβλημάτων. [55]

2.4.2. Επαναλαμβανόμενα Νευρωνικά Δίκτυα (RNN)

Τα RNN αντιπροσωπεύουν μια εξελιγμένη κατηγορία νευρωνικών δικτύων στη σφαίρα της βαθιάς μάθησης, μοναδικά σχεδιασμένα για την επεξεργασία διαδοχικών ή χρονοσειρές δεδομένων. Αυτό τα καθιστά ιδιαίτερα κατάλληλα για εργασίες όπως η αναγνώριση ομιλίας, η αναγνώριση χειρόγραφου και οποιαδήποτε άλλη εφαρμογή όπου το πλαίσιο ή η αλληλουχία των δεδομένων είναι μεγάλης σημασίας.

Το καθοριστικό χαρακτηριστικό των RNN έγκειται στην αρχιτεκτονική τους, η οποία επιτρέπει τη ροή πληροφοριών όχι μόνο προς τα εμπρός, από την είσοδο στην έξοδο, αλλά και μέσω επαναλαμβανόμενων συνδέσεων εντός του δικτύου. Αυτή η αμφίδρομη ροή επιτρέπει στα RNN να διατηρούν μια μορφή μνήμης, καθώς οι έξοδοι από ορισμένους κόμβους μπορούν να κάνουν βρόχο πίσω και να χρησιμεύσουν ως πρόσθετη είσοδος. Αυτός ο μηχανισμός ανάδρασης εξοπλίζει αποτελεσματικά τα RNN με εσωτερικές καταστάσεις ή μνήμη, επιτρέποντάς τους να επεξεργάζονται αυθαίρετες ακολουθίες εισόδων.

Σε αντίθεση με τα νευρωνικά δίκτυα τροφοδοσίας, όπου οι πληροφορίες ρέουν προς μία κατεύθυνση και η έξοδος εξαρτάται αποκλειστικά από την τρέχουσα είσοδο, τα RNN λαμβάνουν υπόψη ολόκληρο το ιστορικό των εισόδων που λαμβάνονται μέχρι ένα δεδομένο σημείο. Αυτό επιτυγχάνεται μέσω των επαναλαμβανόμενων συνδέσεων που επαναφέρουν εξόδους από προηγούμενα χρονικά βήματα πίσω στο δίκτυο. Ως αποτέλεσμα, η έξοδος σε κάθε δεδομένο χρονικό βήμα σε ένα RNN επηρεάζεται όχι μόνο από την τρέχουσα είσοδο αλλά από τη συσσώρευση προηγούμενων εισόδων. [56]



Εικόνα 2..2. Η αμφίδρομη ροή πληροφοριών μεταξύ των κρυφών επιπέδων ως κύριο χαρακτηριστικό των RNN [57]

Σε πρακτικές εφαρμογές, τα RNN έχουν παίξει καθοριστικό ρόλο σε εργασίες που περιλαμβάνουν διαδοχικά ή χρονικά δεδομένα. Για παράδειγμα, στην αναγνώριση ομιλίας, ένα RNN μπορεί να λάβει υπόψη όχι μόνο μεμονωμένα φωνήματα αλλά και τη σειρά και το πλαίσιο στο οποίο εμφανίζονται, οδηγώντας σε πιο ακριβή ερμηνεία και μετάφραση της προφορικής γλώσσας. Ομοίως, στην αναγνώριση χειρογράφου, τα RNN μπορούν να ερμηνεύσουν αποτελεσματικά τη συνεχή, συνδεδεμένη γραφή λαμβάνοντας υπόψη την ακολουθία των πινελιών της πένας.

Ωστόσο, τα παραδοσιακά RNN με τυπικά κελιά όπως οι σιγμοειδής μονάδες ή μονάδες υπερβολικής εφαπτομένης συνάρτησης (\tanh), αντιμετωπίζουν προκλήσεις, ιδιαίτερα όταν ασχολούνται με μεγάλες ακολουθίες εισόδου. Τείνουν να δυσκολεύονται να μάθουν σχετικές πληροφορίες από δεδομένα όπου σημαντικά κενά ή εξαρτήσεις εκτείνονται σε μεγάλες ακολουθίες. Αυτό οφείλεται κυρίως στο πρόβλημα της εξαφάνισης της κλίσης, όπου η επίδραση των δεδομένων εισόδου μειώνεται καθώς ταξιδεύει σε πολλά χρονικά βήματα, καθιστώντας δύσκολο για το δίκτυο να διατηρήσει μακροπρόθεσμες εξαρτήσεις. [57]

Αυτό το ζήτημα οδήγησε στην ανάπτυξη του Δικτύου Μακροβραχυπρόθεσμης Μνήμης (LSTM), μιας παραλλαγής του RNN που ενσωματώνει λειτουργίες πύλης στη δομή του. Αυτές οι πύλες ελέγχουν τη ροή των πληροφοριών, επιτρέποντας στο δίκτυο να διατηρεί ή να ξεχνάει πληροφορίες επιλεκτικά. Αυτή η αρχιτεκτονική βελτίωση επιτρέπει στα LSTM να χειρίζονται τις μακροπρόθεσμες εξαρτήσεις πιο αποτελεσματικά από τα παραδοσιακά RNN.

Τα LSTM έχουν γίνει κομβικό σημείο στην έρευνα βαθιάς μάθησης λόγω της ενισχυμένης ικανότητάς τους στη διαχείριση δεδομένων ακολουθίας, ιδιαίτερα σε περιβάλλοντα όπου η διατήρηση πληροφοριών για παρατεταμένη περίοδο είναι σημαντική. Έχουν βρει ευρείες εφαρμογές σε τομείς όπως η μηχανική μετάφραση, η σύνοψη κειμένου και πιο σύνθετες εργασίες εκμάθησης ακολουθίας, όπου η κατανόηση της χρονικής δυναμικής και των εξαρτήσεων μέσα στα δεδομένα είναι απαραίτητη. [58]

2.4.3. Συνελικτικά Νευρωνικά Δίκτυα (CNN)

Τα CNN έχουν αναδειχθεί ως βασική τεχνολογία στη βαθιά μάθηση, ιδιαίτερα στον τομέα της ταξινόμησης εικόνων. Η προτίμησή τους έναντι άλλων αρχιτεκτονικών νευρωνικών δικτύων όπως τα RNN και τα MLP για εργασίες που σχετίζονται με την εικόνα πηγάζει από τη μοναδική τους ικανότητα να επεξεργάζονται και να ερμηνεύουν οπτικά δεδομένα.

Τα RNN, αν και είναι εξαιρετικά στο χειρισμό διαδοχικών δεδομένων όπως κείμενο ή χρονοσειρές, δεν είναι εγγενώς σχεδιασμένα για να αναγνωρίζουν χωρικές ιεραρχίες και μοτίβα σε εικόνες. Τα MLP, παρά την ευελιξία τους, υπολείπονται επίσης από αυτή την άποψη λόγω της πλήρως συνδεδεμένης φύσης τους, οδηγώντας σε μεγάλο αριθμό παραμέτρων όταν ασχολούμαστε με μεγάλα δεδομένα εισόδου, όπως εικόνες. Αυτό καθιστά τα MLP υπολογιστικά ακριβά και λιγότερο αποτελεσματικά στην αποτύπωση των τοπικών χωρικών συσχετισμών που υπάρχουν στις εικόνες.

Αντίθετα, τα CNN έχουν σχεδιαστεί ρητά για να αναγνωρίζουν και να εκμεταλλεύονται τα χωρικά και ιεραρχικά μοτίβα στα οπτικά δεδομένα, καθιστώντας τα ιδιαίτερα κατάλληλα για εργασίες όπως η ταξινόμηση εικόνων MRI. Αυτό το επιτυγχάνουν χρησιμοποιώντας συνελικτικά στρώματα, τα οποία μειώνουν τον αριθμό των εκπαιδευσιμων παραμέτρων, εστιάζοντας αντ' αυτού σε τοπικά δεκτικά πεδία και κοινά βάρη. Αυτή η προσέγγιση επιτρέπει στα CNN να μαθαίνουν αποτελεσματικά τα σχετικά χαρακτηριστικά από εικόνες, όπως άκρες, υφές και, τελικά, πιο περίπλοκα μοτίβα, χωρίς την ανάγκη χειροκίνητης εξαγωγής χαρακτηριστικών. [59]

Η αρχιτεκτονική των CNN είναι σχολαστικά σχεδιασμένη για να αντικατοπτρίζει τον τρόπο με τον οποίο η ανθρώπινη όραση αναλύει οπτικά δεδομένα. Αποτελούνται από στρώματα που το καθένα εκτελεί ξεχωριστές λειτουργίες: συνελικτικά στρώματα για εξαγωγή χαρακτηριστικών, στρώματα συγκέντρωσης για μείωση διαστάσεων και πλήρως συνδεδεμένα στρώματα για ταξινόμηση. Τα συνελικτικά στρώματα χρησιμοποιούν φίλτρα για να εκτελούν περιελίξεις κατά μήκος της εικόνας εισόδου, καταγράφοντας βασικά οπτικά χαρακτηριστικά. Στη συνέχεια, τα επίπεδα συγκέντρωσης μειώνουν το χωρικό μέγεθος της αναπαράστασης, μειώνοντας τον αριθμό των παραμέτρων και τον υπολογισμό στο δίκτυο, ελέγχοντας έτσι την υπερπροσαρμογή.

Η επιτυχία των CNN στην ταξινόμηση εικόνων, ειδικά στην ιατρική απεικόνιση όπως η μαγνητική τομογραφία, οφείλεται επίσης στην ικανότητά τους να χειρίζονται την υψηλή μεταβλητότητα που είναι εγγενής στα οπτικά δεδομένα. Για παράδειγμα, στην ταξινόμηση εικόνων MRI, τα CNN μπορούν να μάθουν να εντοπίζουν μοτίβα και ανωμαλίες ειδικά για διάφορες ιατρικές καταστάσεις, παρά τις διαφορές στα σχήματα, τα μεγέθη και τις θέσεις αυτών των ανωμαλιών σε διαφορετικές εικόνες.

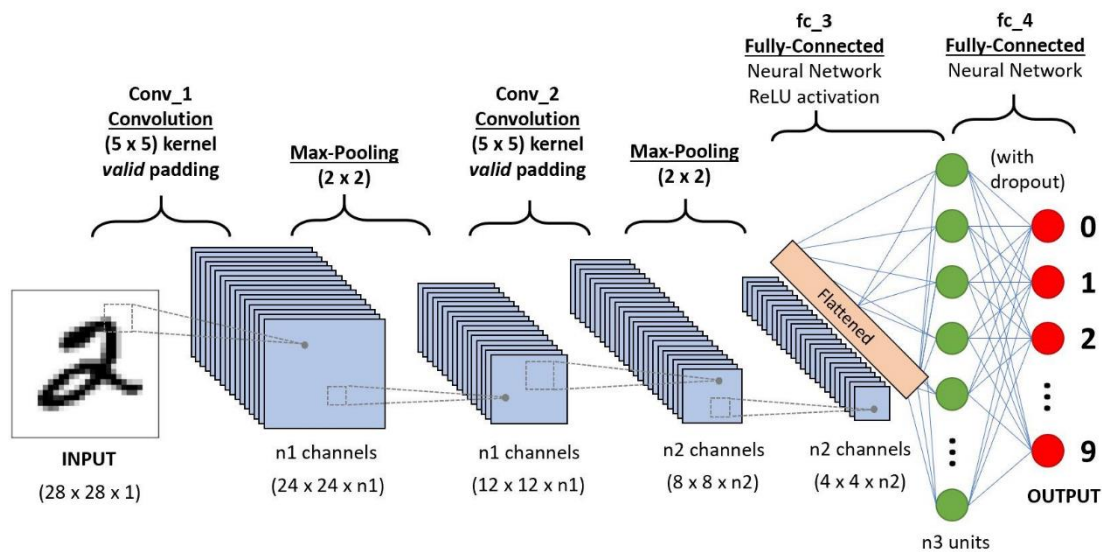
Επιπλέον, οι πρόσφατες εξελίξεις στις αρχιτεκτονικές του CNN έχουν συμβάλει σημαντικά στην επιτυχία τους στην ταξινόμηση εικόνων. Αρχιτεκτονικές όπως το AlexNet, το VGG και το ResNet [60] έχουν ξεπεράσει τα όρια του δυνατού στην όραση υπολογιστή, επιτυγχάνοντας αποτελέσματα αιχμής σε διάφορες εργασίες ταξινόμησης εικόνων. Αυτές οι αρχιτεκτονικές έχουν αποδείξει την ικανότητα των CNN να χειρίζονται πολύπλοκα προβλήματα ταξινόμησης εικόνων, συμπεριλαμβανομένων αυτών που απαντώνται στην ιατρική απεικόνιση, με αξιοσημείωτη ακρίβεια και αποτελεσματικότητα. [60][61]

Θα εμβαθύνουμε στα συγκεκριμένα δομικά στοιχεία των CNN, στις μαθηματικές τους βάσεις και στις μεθοδολογίες που χρησιμοποιούνται για την

εκπαίδευση και τη βελτιστοποίηση αυτών των δικτύων. Αυτό θα περιλαμβάνει μια εξερεύνηση των συνελκτικών λειτουργιών, των συναρτήσεων ενεργοποίησης, των μεθόδων back-propagation και διαφόρων στρατηγικών βελτιστοποίησης που συμβάλλουν συλλογικά στις ισχυρές δυνατότητες των CNN στις εργασίες ταξινόμησης εικόνων. Αυτή η λεπτομερής εξέταση θα υπογραμμίσει γιατί τα CNN δεν είναι μόνο η προτιμώμενη επιλογή για εργασίες γενικής ταξινόμησης εικόνων, αλλά επίσης υπόσχονται σημαντικές για εξειδικευμένες εφαρμογές όπως η ταξινόμηση εικόνων MRI στον ιατρικό τομέα.

2.5. Βασική Αρχιτεκτονική CNN

Σε αυτό το κεφάλαιο, ξεκινάμε μια λεπτομερή εξερεύνηση της θεμελιώδους αρχιτεκτονικής των CNN. Στην καρδιά των CNN βρίσκεται η μοναδική τους ικανότητα να εντοπίζουν αυτόματα και να μαθαίνουν ιεραρχικά μοτίβα σε οπτικά δεδομένα. Θα πραγματοποιηθεί ανάλυση στην πολυεπίπεδη δομή τους, εμβαθύνοντας στις περιπλοκές κάθε στοιχείου, από συνελκτικά επίπεδα που καταγράφουν χωρικές ιεραρχίες, σε επίπεδα ομαδοποίησης (pooling) που μειώνουν τις διαστάσεις και πλήρως συνδεδεμένα (fully-connected) επίπεδα που ενσωματώνουν αυτά τα μαθημένα χαρακτηριστικά για εργασίες ταξινόμησης ή παλινδρόμησης. Αυτό το ταξίδι στην αρχιτεκτονική των CNN όχι μόνο θα αποσαφηνίσει τις επιχειρησιακές τους αρχές αλλά και θα δια φωτίσει γιατί αντιπροσωπεύουν ένα τόσο μεταμορφωτικό εργαλείο στο τοπίο της τεχνητής νοημοσύνης και της μηχανικής μάθησης.



Εικόνα 2.3. Οπτικοποίηση δεδομένων που διέρχονται από ένα συνελκτικό νευρωνικό δίκτυο [62]

2.5.1. Επίπεδο Εισόδου (Input Layer)

Το επίπεδο εισόδου σε ένα CNN χρησιμεύει ως σημείο εισόδου για ολόκληρο το δίκτυο. Είναι όπου το CNN λαμβάνει τα αρχικά ακατέργαστα δεδομένα του. Στο πλαίσιο της επεξεργασίας εικόνας, η οποία είναι μια κοινή εφαρμογή για CNN, το επίπεδο εισόδου αποτελείται συνήθως από τιμές pixel της εικόνας. Οι εικόνες αντιπροσωπεύονται ως πολυδιάστατοι πίνακες ή πίνακες εικονοστοιχείων. Για παράδειγμα, μια τυπική εικόνα σε κλίμακα του γκρι μπορεί να αναπαρασταθεί ως

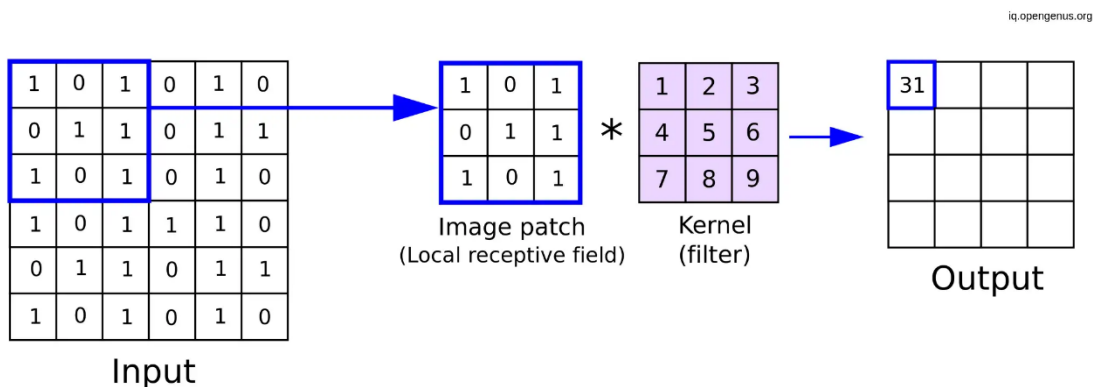
έναν δισδιάστατο πίνακα όπου κάθε στοιχείο αντιστοιχεί στην ένταση ενός pixel. Στην περίπτωση των έγχρωμων εικόνων, ιδιαίτερα εκείνων σε μορφή RGB (κόκκινο, πράσινο, μπλε), η αναπαράσταση περιλαμβάνει έναν τρισδιάστατο πίνακα για να φιλοξενήσει τα τρία έγχρωμα κανάλια. [63]

2.5.2. Συνελικτικό Επίπεδο (Convolutional Layer)

Το συνελικτικό επίπεδο είναι ένα θεμελιώδες συστατικό ενός CNN και αναφέρεται συνήθως ως το επίπεδο εξαγωγής χαρακτηριστικών. Διαδραματίζει κρίσιμο ρόλο στην επεξεργασία και ερμηνεία δεδομένων εικόνας εξάγοντας σημαντικά χαρακτηριστικά από την είσοδο, όπως άκρες, υφές και πιο σύνθετα μοτίβα σε υψηλότερα επίπεδα.

Στον πυρήνα του, ένα συνελικτικό στρώμα αποτελείται από ένα σύνολο φίλτρων ή πυρήνων, που είναι μικρές μήτρες βαρών. Αυτά τα φίλτρα έχουν σχεδιαστεί για να συμπλέκονται ή να “γλιστρούν” πάνω από την εικόνα εισόδου, καλύπτοντας συστηματικά κάθε μέρος της. Το μέγεθος αυτών των φίλτρων είναι γενικά μικρότερο από την εικόνα εισόδου και εφαρμόζονται σε τοπικές περιοχές της εισόδου, γνωστές ως δεκτικά πεδία. Το πεδίο λήψης αντιστοιχεί στο τμήμα της εικόνας που επεξεργάζεται αυτή τη στιγμή το φίλτρο και έχει τις ίδιες διαστάσεις με το ίδιο το φίλτρο.

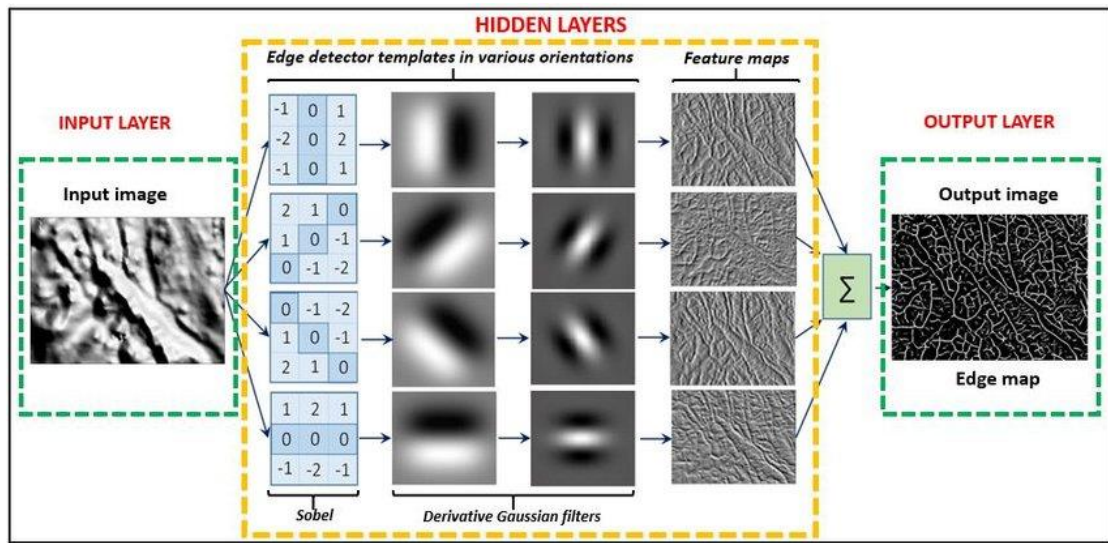
Κατά τη διαδικασία συνέλιξης, το φίλτρο εκτελεί έναν πολλαπλασιασμό βάσει στοιχείων με τις τιμές στο πεδίο υποδοχής και στη συνέχεια συνοψίζει τα αποτελέσματα, παράγοντας έναν μόνο ακέραιο στον χάρτη χαρακτηριστικών εξόδου, όπως παρουσιάζεται παρακάτω στην *Εικ. 2.4*. Αυτή η έξοδος είναι μια συμπυκνωμένη αναπαράσταση της παρουσίας και της έντασης συγκεκριμένων χαρακτηριστικών σε διάφορες θέσεις στην εικόνα εισόδου. Καθώς το φίλτρο “γλιστρά” πάνω από την εικόνα εισόδου, μετακινείται κατά έναν συγκεκριμένο αριθμό pixel κάθε φορά, γνωστό ως διασκελισμός. Η διαδικασία επαναλαμβάνεται για κάθε θέση του φίλτρου πάνω από την εικόνα, με αποτέλεσμα έναν ολοκληρωμένο χάρτη χαρακτηριστικών που αντιπροσωπεύει την απόκριση του φίλτρου στην εικόνα εισόδου.



Εικόνα 2.4. Λειτουργία συνέλιξης με φίλτρο (kernel) 3×3 [64]

Κάθε φίλτρο σε ένα συνελικτικό επίπεδο είναι υπεύθυνο για την ανίχνευση ενός συγκεκριμένου χαρακτηριστικού, όπως ένας συγκεκριμένος προσανατολισμός άκρων ή ένα μοτίβο [65]. Με τη στοίβαξη πολλαπλών φίλτρων σε ένα μόνο συνελικτικό επίπεδο, το δίκτυο μπορεί ταυτόχρονα να ανιχνεύσει διάφορα χαρακτηριστικά. Η έξοδος του επιπέδου, επομένως, αποτελείται από πολλαπλούς

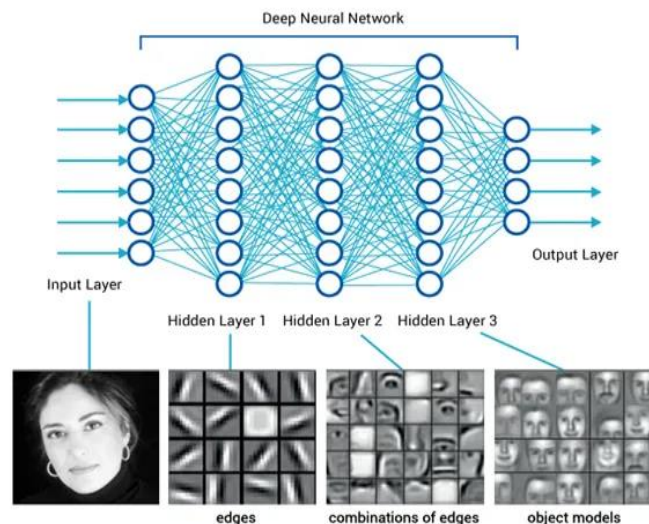
χάρτες χαρακτηριστικών, ο καθένας αντιστοιχεί στην απόκριση ενός φίλτρου, όπως φαίνεται στην *Εικ. 2.5.* Το βάθος του όγκου εξόδου του συνελκτικού στρώματος είναι ίσο με τον αριθμό των φίλτρων που χρησιμοποιούνται.



Εικόνα 2.5. Ανίχνευση ακρών μέσω Γκαουσιανών φίλτρων [66]

Η ομορφιά των συνελκτικών επιπέδων έγκειται στην τοπική συνδεσιμότητα και την κοινή χρήση παραμέτρων. Κάθε νευρώνας (ή μονάδα) στον χάρτη χαρακτηριστικών συνδέεται μόνο με μια μικρή τοπική περιοχή στην είσοδο, που ορίζεται από το μέγεθος του φίλτρου. Επιπλέον, όλοι οι νευρώνες στον ίδιο χάρτη χαρακτηριστικών μοιράζονται τις ίδιες παραμέτρους φίλτρου, μειώνοντας σημαντικά τον αριθμό των παραμέτρων σε σύγκριση με ένα πλήρως συνδεδεμένο επίπεδο και δίνοντας τη δυνατότητα στο δίκτυο να μαθαίνει αποτελεσματικά.

Στην πράξη, τα πρώτα συνελκτικά στρώματα σε ένα CNN τείνουν να καταγράφουν χαρακτηριστικά χαμηλού επιπέδου, όπως γραμμές και άκρες, ενώ τα βαθύτερα στρώματα μπορούν να εξάγουν πιο περίπλοκα, υψηλού επιπέδου χαρακτηριστικά, όπως σχήματα ή συγκεκριμένα αντικείμενα, όπως παρατηρείται στην *Εικ. 2.6.* Αυτός ο ιεραρχικός μηχανισμός εξαγωγής χαρακτηριστικών είναι που κάνει τα CNN ιδιαίτερα αποτελεσματικά για εργασίες που σχετίζονται με την εικόνα, επιτρέποντάς τους να αναγνωρίζουν και να ταξινομούν οπτικά μοτίβα με αξιοσημείωτη ακρίβεια. [67]



Εικόνα 2.6. Οπτική αναπαράσταση εξαγωγής περιπλοκότερων χαρακτηριστικών με τον συνδυασμό πολλαπλών συνελκτικών επιπέδων [67]

Μαθηματικά, η λειτουργία συνέλιξης μπορεί να περιγραφεί ως εξής:

Έστω ότι εισάγεται μια εικόνα εισόδου ή ένας χάρτης χαρακτηριστικών I , με διαστάσεις $H \times W \times D$, όπου H αντιπροσωπεύει το ύψος, W αντιπροσωπεύει το πλάτος και D αντιπροσωπεύει το βάθος (αριθμός καναλιών).

Ένας συνελκτικός πυρήνας K με διαστάσεις $F \times F \times D$ εφαρμόζεται σε αυτήν την είσοδο. Το F αντιπροσωπεύει το μέγεθος του φίλτρου (τόσο το ύψος όσο και το πλάτος του φίλτρου) και το D αντιπροσωπεύει το βάθος του φίλτρου, το οποίο πρέπει να ταιριάζει με το βάθος της εισόδου.

Ο χάρτης χαρακτηριστικών εξόδου O υπολογίζεται ολισθαίνοντας τον πυρήνα πάνω από την είσοδο:

$$O_{i,j,k} = \sigma \left(\sum_{l=0}^{D-1} \sum_{m=0}^{F-1} \sum_{n=0}^{F-1} I_{i+m,j+n,l} \times K_{m,n,l,k} + b_k \right)$$

Όπου:

$O_{i,j,k}$: είναι η τιμή στη θέση (i, j) στον k^{th} χάρτη χαρακτηριστικών της εξόδου.

σ : αντιπροσωπεύει τη συνάρτηση ενεργοποίησης που εφαρμόζεται στα στοιχεία (π.χ. ReLU, σιγμοειδές, κ.λπ.).

$I_{i+m,j+n,l}$: αντιπροσωπεύει την τιμή εισόδου στη θέση $(i + m, j + n)$ στο κανάλι l^{th} της εισόδου.

$K_{m,n,l,k}$: είναι το βάρος του πυρήνα στη θέση (m, n) στο l^{th} κανάλι της εισόδου και του k^{th} φίλτρου.

b_k : είναι ο όρος bias για το k^{th} φίλτρο.

[68]

Στη σφαίρα των CNN, οι συναρτήσεις ενεργοποίησης διαδραματίζουν κεντρικό ρόλο, λειτουργώντας ως καταλύτες για την εισαγωγή μη γραμμικότητας στο δίκτυο. Αυτή η μη γραμμικότητα είναι απαραίτητη. Χωρίς αυτό, ένα CNN, ανεξάρτητα από το βάθος του, θα λειτουργούσε ουσιαστικά ως ένα απλό γραμμικό perceptron, ανίκανο να χειριστεί τις περίπλοκες εργασίες για τις οποίες είναι γνωστό. Οι συναρτήσεις ενεργοποίησης επιτρέπουν στα CNN να μαθαίνουν και να εκτελούν εξελιγμένες λειτουργίες μετατρέποντας τη γραμμική είσοδο που λαμβάνεται από τα προηγούμενα επίπεδα σε μια μη γραμμική έξοδο.

Το συνελκτικό επίπεδο, συγκεκριμένα, αξιοποιεί τη δύναμη των λειτουργιών ενεργοποίησης για να μετατρέψει τα ακατέργαστα, γραμμικά επεξεργασμένα δεδομένα από τη λειτουργία συνέλιξης σε μια μορφή κατάλληλη για περαιτέρω περίπλοκη επεξεργασία. Αυτός ο μετασχηματισμός είναι κρίσιμος επειδή ο πραγματικός κόσμος είναι εγγενώς μη γραμμικός και για να συλλάβει τις περιπλοκές των δεδομένων όπως οι εικόνες, το μοντέλο πρέπει να υπερβαίνει τις γραμμικές ερμηνείες. [69]


Έχοντας καθιερώσει τον απαραίτητο ρόλο των συναρτήσεων ενεργοποίησης στα CNN, είναι κρίσιμο να επισημανθούν οι συγκεκριμένοι τύποι συναρτήσεων ενεργοποίησης και η μοναδική τους συμβολή στην ικανότητα εκμάθησης του δικτύου. Κάθε λειτουργία ενεργοποίησης, είτε είναι ReLU, Leaky ReLU, PReLU ή ELU, φέρνει ξεχωριστά χαρακτηριστικά και πλεονεκτήματα στον πίνακα. Αυτές οι συναρτήσεις διαφέρουν ως προς τον τρόπο με τον οποίο χειρίζονται τις αρνητικές εισόδους, διαχειρίζονται τη ροή κλίσης και επηρεάζουν τη συνολική δυναμική εκμάθησης του δικτύου. Καθώς περνάμε σε μια λεπτομερή εξέταση καθεμιάς από αυτές τις συναρτήσεις, αναφέρονται οι μαθηματικές τους διατυπώσεις, τα συγκεκριμένα προβλήματα που αντιμετωπίζουν και ο αντίκτυπος που έχουν στην ικανότητα του δικτύου να συλλαμβάνει πολύπλοκα μοτίβα σε δεδομένα. Αυτή η

εξερεύνηση όχι μόνο θα τονίσει τις αποχρώσεις αυτών των λειτουργιών, αλλά θα παρέχει επίσης πληροφορίες για το γιατί και πώς χρησιμοποιούνται επιλεκτικά σε διάφορα επίπεδα CNN για τη βελτιστοποίηση της απόδοσης, ειδικά σε εργασίες που περιλαμβάνουν περίπλοκα δεδομένα εικόνας.

2.5.3. Συναρτήσεις Ενεργοποίησης

Διορθωμένη Γραμμική Μονάδα (ReLU)

Η λειτουργία ενεργοποίησης ReLU, λόγω της απλότητας και της αποτελεσματικότητάς της, έχει γίνει πρότυπο στην αρχιτεκτονική των CNN. Στον πυρήνα του, το ReLU εισάγει τη μη γραμμικότητα στο δίκτυο, η οποία είναι σημαντική για την εκμάθηση πολύπλοκων μοτίβων στα δεδομένα, ιδιαίτερα σε εφαρμογές όπως η ταξινόμηση εικόνων και η ανίχνευση αντικειμένων.



(a) ReLU

Εικόνα 2.7. Γράφημα της συνάρτησης ενεργοποίησης ReLU [70]

Βασικά, το ReLU λειτουργεί με έναν απλό μηχανισμό, επιτρέπει στις θετικές τιμές από την είσοδο του να περάσουν αμετάβλητες, ενώ οποιαδήποτε αρνητική τιμή ορίζεται στο μηδέν. Αυτό μπορεί να αναπαρασταθεί μαθηματικά ως $f(x) = \max(0, x)$ (βλ. Εικ. 2.7.), όπου x είναι η είσοδος στη συνάρτηση. Το πρωταρχικό πλεονέκτημα αυτής της συνάρτησης είναι η ικανότητά της να μετριάξει το πρόβλημα της κλίσης που εξαφανίζεται, μια κοινή πρόκληση στην εκπαίδευση των βαθιών νευρωνικών δικτύων. Αυτό το πρόβλημα παρουσιάζεται όταν οι κλίσεις, κατά τη διάρκεια της οπίσθιας διάδοσης, γίνονται υπερβολικά μικρές, οδηγώντας σε σημαντική επιβράδυνση ή ακόμα και διακοπή της διαδικασίας εκμάθησης. Διασφαλίζοντας ότι η κλίση είναι είτε μηδέν (για αρνητικές εισόδους) είτε ένα (για θετικές εισόδους), το ReLU διατηρεί μια συνεπή ροή διαβαθμίσεων, βοηθώντας έτσι στην ταχύτερη και πιο αποτελεσματική εκπαίδευση των βαθιών νευρικών μοντέλων. [71]

Στο πλαίσιο των CNN, η συνάρτηση ReLU εφαρμόζεται στην έξοδο των επιπέδων συνέλιξης για να εισαγάγει μη γραμμικότητα στους χάρτες χαρακτηριστικών. Αυτή η μη γραμμικότητα είναι απαραίτητη επειδή τα δεδομένα του πραγματικού κόσμου, ειδικά οι εικόνες, είναι εγγενώς μη γραμμικά. Έτσι, το ReLU βοηθά το δίκτυο στην εκμάθηση μη γραμμικών αναπαραστάσεων, επιτρέποντάς του να κατανοεί και να ερμηνεύει καλύτερα σύνθετες οπτικές πληροφορίες.

Ωστόσο, η λειτουργία ReLU δεν είναι χωρίς τις αδυναμίες της. Ένα αξιοσημείωτο ζήτημα είναι το πρόβλημα του «νεκρού νευρώνα», όπου οι νευρώνες μπορούν να γίνουν ανενεργοί και να δίνουν σταθερά μηδέν για οποιαδήποτε δεδομένη είσοδο. Αυτό το πρόβλημα προκύπτει επειδή από τη στιγμή που ένας νευρώνας αρχίσει να βγάζει μηδέν, είναι πιθανό να συνεχίσει να το κάνει, καθώς η κλίση μέσω μιας μονάδας ReLU είναι μηδέν κάθε φορά που η είσοδος του είναι


αρνητική. Ως αποτέλεσμα, τμήματα του νευρωνικού δικτύου μπορεί να γίνουν ανενεργά, μειώνοντας την ικανότητά του να μαθαίνει.

Για την αντιμετώπιση αυτών των περιορισμών, έχουν αναπτυχθεί διάφορες τροποποιημένες εκδόσεις του ReLU, όπως το Leaky ReLU και το Parametric ReLU (PReLU). Αυτές οι παραλλαγές εισάγουν μια μικρή κλίση στο αρνητικό μέρος της συνάρτησης, διασφαλίζοντας ότι υπάρχει πάντα κάποια κλίση που ρέει μέσω της μονάδας, ακόμη και για αρνητικές εισόδους. [72]

Διαρρέουσα Διορθωμένη Γραμμική Μονάδα (Leaky Relu)

Βασισμένο στα θεμέλια που τίθενται από την τυπική λειτουργία ενεργοποίησης ReLU, το Leaky ReLU αναδεικνύεται ως μια καινοτόμος λύση για την αντιμετώπιση ενός από τους σημαντικούς περιορισμούς του ReLU, το πρόβλημα του "νεκρού νευρώνα". Αυτό αντιμετωπίζεται εισάγοντας μια μικρή, θετική κλίση στην περιοχή όπου η είσοδος είναι αρνητική. Αυτή η τροποποίηση διασφαλίζει ότι οι νευρώνες παραμένουν ενεργοί, ακόμη και όταν αντιμετωπίζονται αρνητικές εισόδους. Η μαθηματική αναπαράσταση του Leaky ReLU είναι:

$$f(x) = \begin{cases} x & \text{if } x > 0 \\ \alpha x & \text{otherwise} \end{cases}$$



Εικόνα 2.8. Γράφημα της συνάρτησης ενεργοποίησης Leaky ReLU [73]

Εδώ, το α είναι μια μικρή σταθερά (όπως 0,01), η οποία αντιπροσωπεύει την κλίση της συνάρτησης για αρνητικές τιμές εισόδου. Σε αντίθεση με το τυπικό ReLU, το οποίο βγάζει μηδέν για οποιαδήποτε αρνητική είσοδο, το Leaky ReLU επιτρέπει μια μικρή κλίση όταν η είσοδος είναι αρνητική, όπως φαίνεται στην *Εικ. 2.8.* Αυτή η συνεχής ροή μιας μικρής κλίσης κρατά τους νευρώνες «ζωντανούς», εμποδίζοντάς τους να γίνουν «νεκροί» ή ανενεργοί.

Η έννοια του Leaky ReLU είναι ιδιαίτερα χρήσιμη σε σενάρια όπου ο ρυθμός εκμάθησης είναι υψηλός, γεγονός που μπορεί συχνά να οδηγήσει στο πρόβλημα του "νεκρού νευρώνα" με το τυπικό ReLU. Σε τέτοιες περιπτώσεις, η ικανότητα του Leaky ReLU να επιτρέπει μια μικρή κλίση για αρνητικές εισόδους βοηθά το δίκτυο να συνεχίσει να μαθαίνει, αν και με πιο αργό ρυθμό από ό,τι για τις θετικές εισόδους.

Ενώ το Leaky ReLU έχει αποδειχθεί ότι διατηρεί σταθερή ενεργοποίηση νευρώνων και ανακουφίζει το πρόβλημα του νεκρού νευρώνα, ο αντίκτυπός του στη συνολική ακρίβεια και απόδοση των βαθιών νευρωνικών δικτύων σε σύγκριση με το τυπικό ReLU υπόκειται σε συνεχή έρευνα και συζήτηση. Ορισμένες μελέτες υποδεικνύουν ότι το Leaky ReLU μπορεί να ξεπεράσει το αρχικό ReLU, ειδικά σε περιπτώσεις όπου το πρόβλημα του νεκρού νευρώνα είναι εμφανές. Ωστόσο, η έκταση αυτής της βελτίωσης της απόδοσης και οι συγκεκριμένες συνθήκες υπό τις οποίες το Leaky ReLU επιδεικνύει ανώτερη απόδοση παραμένουν τομείς ενεργούς εξερεύνησης.

Παραμετρική Διορθωμένη Γραμμική Μονάδα (PReLU)


Το PReLU είναι μια καινοτόμος ανατροπή των παραδοσιακών συναρτήσεων ενεργοποίησης ReLU και Leaky ReLU, προσθέτοντας ένα προσαρμόσιμο στοιχείο που ενισχύει περαιτέρω τις δυνατότητες των νευρωνικών δικτύων. Η μοναδικότητα του PReLU έγκειται στην ικανότητά του να μαθαίνει την κλίση της συνάρτησης ενεργοποίησης για αρνητικές εισόδους ως μέρος της διαδικασίας εκπαίδευσης του μοντέλου. Αυτή η προσαρμοστικότητα επιτρέπει στο PReLU να προσαρμόζει δυναμικά τη συμπεριφορά του με βάση τα συγκεκριμένα χαρακτηριστικά των δεδομένων που επεξεργάζεται.

Μαθηματικά, το PReLU εκφράζεται ως:

$$PReLU(x) = \max(0, x) + \alpha * \min(0, x)$$

$$PReLU(x) = \begin{cases} x, & x \geq 0 \\ \alpha x, & \text{otherwise} \end{cases}$$

όπου το α είναι μια εκμαθήσιμη παράμετρος που αντιπροσωπεύει την κλίση της συνάρτησης για αρνητικές εισόδους. Με απλούστερους όρους, το PReLU λειτουργεί παρόμοια με το ReLU για θετικές εισόδους, περνώντας τις αμετάβλητες, ενώ για τις αρνητικές εισόδους, τις πολλαπλασιάζει με μια μαθημένη παράμετρο α , αντί για μια σταθερή μικρή τιμή όπως στο Leaky ReLU.



Εικόνα 2.9. Γράφημα συνάρτησης ενεργοποίησης PReLU [74]

Η εισαγωγή αυτής της παραμέτρου α εκμάθησης σημαίνει ότι το PReLU μπορεί να προσαρμόσει τη συμπεριφορά του κατά τη διάρκεια της εκπαιδευτικής διαδικασίας. Σε αντίθεση με το Leaky ReLU, όπου η κλίση για τις αρνητικές εισόδους είναι προκαθορισμένη και σταθερή, η κλίση του PReLU μπορεί να ποικίλλει μεταξύ διαφορετικών μονάδων του δικτύου ή να αλλάξει κατά τη διάρκεια της εκπαίδευσης. Αυτή η ευελιξία επιτρέπει στο PReLU να προσαρμόζει την απόκρισή του σε αρνητικές εισόδους με βάση το συνολικό πλαίσιο μάθησης του δικτύου.

Στα CNN, η εφαρμογή του PReLU μπορεί να είναι ακόμη πιο λεπτομερής. Μπορεί να εφαρμοστεί ανά επίπεδο ή ακόμα και ανά κανάλι σε κάθε επίπεδο, προσφέροντας υψηλό βαθμό προσαρμογής. Αυτό είναι ιδιαίτερα χρήσιμο σε μοντέλα βαθιάς μάθησης όπου διαφορετικά επίπεδα ενδέχεται να απαιτούν διαφορετικούς τύπους μη γραμμικότητας. Για παράδειγμα, τα αρχικά επίπεδα μπορεί να επωφεληθούν από μια πιο γραμμική απόκριση (υψηλότερη τιμή α) για τη διατήρηση περισσότερων πληροφοριών, ενώ τα βαθύτερα στρώματα μπορεί να υιοθετήσουν μια πιο παραδοσιακή συμπεριφορά παρόμοια με το ReLU (χαμηλότερη τιμή α) για να ενισχύσουν τη διακριτικότητα του μοντέλου.

Ωστόσο, η πρόσθετη ευελιξία του PReLU έχει κόστος. Η εισαγωγή του α ως εκμάθησης παραμέτρου αυξάνει την πολυπλοκότητα του μοντέλου. Αυτή η πρόσθετη


παράμετρος πρέπει να ρυθμιστεί με ακρίβεια, κάτι που μπορεί να είναι χρονοβόρο και υπολογιστικά απαιτητικό, ιδιαίτερα για μοντέλα που ασχολούνται με μεγάλα και διαφορετικά σύνολα δεδομένων. Επιπλέον, όπως συμβαίνει με κάθε μοντέλο με περισσότερες παραμέτρους, υπάρχει αυξημένος κίνδυνος υπερπροσαρμογής, που απαιτεί προσεκτική χρήση τεχνικών κανονικοποίησης. [75]

Εκθετική Γραμμική Μονάδα (ELU)

Η ELU αντιπροσωπεύει μια αξιοσημείωτη πρόοδο στις συναρτήσεις ενεργοποίησης που χρησιμοποιούνται στα νευρωνικά δίκτυα, ιδιαίτερα για εφαρμογές βαθιάς μάθησης. Λειτουργεί με βάση την αρχή της χρήσης εκθετικών συναρτήσεων για να παρέχει ομαλότερες και πιο συνεπείς ενεργοποιήσεις για αρνητικές εισόδους σε σύγκριση με τους προκατόχους του, όπως το ReLU.

Το ELU ορίζεται μαθηματικά από τη συνάρτηση:

$$ELU(x) = \begin{cases} x, & x > 0 \\ \beta(e^x - 1), & x \leq 0 \end{cases}$$



Εικόνα 2.10. Γράφημα συνάρτησης ενεργοποίησης ELU για διαφορετικές σταθερές β [76]

Για θετικές τιμές του x , το ELU συμπεριφέρεται παρόμοια με το ReLU, επιτρέποντας στην είσοδο να περάσει αμετάβλητη, διατηρώντας έτσι τα οφέλη της συνάρτησης ταυτότητας. Ωστόσο, για τις αρνητικές τιμές του x , η ELU εισάγει μια νέα συστροφή. Αντί να μηδενίζει αυτές τις τιμές, όπως κάνει το ReLU, ή να τις πολλαπλασιάζει με μια σταθερά, όπως στην περίπτωση του Leaky ReLU, το ELU εφαρμόζει μια συνάρτηση εκθετικής αποσύνθεσης. Αυτό έχει ως αποτέλεσμα μια ομαλή καμπύλη (όπως φαίνεται στην *Εικ. 2.10.*) που προσεγγίζει μια αρνητική σταθερά β , καθώς το x τείνει προς το αρνητικό άπειρο.

Ένα από τα σημαντικά πλεονεκτήματα του ELU σε σχέση με άλλες λειτουργίες ενεργοποίησης είναι η ικανότητά του να παράγει ενεργοποιήσεις με μέσο όρο πιο κοντά στο μηδέν. Αυτή η ιδιότητα επιταχύνει τη μάθηση επειδή φέρνει τη διαβάθμιση πιο κοντά στη φυσική κλίση, μειώνοντας έτσι το φαινόμενο μετατόπισης μεροληψίας που παρατηρείται συνήθως με τις ενεργοποιήσεις ReLU, οι οποίες τείνουν να είναι θετικές κατά μέσο όρο.

Ο σχεδιασμός του ELU του επιτρέπει να μειώνει τη διακύμανση προς τα εμπρός και τις πληροφορίες για αρνητικές εισόδους, μειώνοντας τον αντίκτυπο του θορύβου και των διαταραχών στη διαδικασία εκμάθησης. Αυτό το χαρακτηριστικό

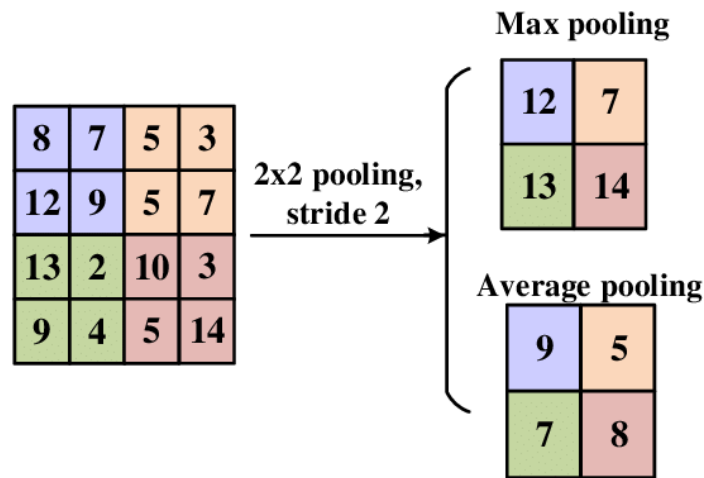
καθιστά τις ELU ιδιαίτερα αποτελεσματικές στην κωδικοποίηση της παρουσίας χαρακτηριστικών στα δεδομένα εισόδου χωρίς να ανταποκρίνεται υπερβολικά στην απουσία τους.

Στην πράξη, τα δίκτυα που χρησιμοποιούν ELU έχουν αποδειχθεί ότι ξεπερνούν εκείνα που χρησιμοποιούν το ReLU και τις παραλλαγές του σε διάφορα σύνολα δεδομένων όρασης, επιτυγχάνοντας ταχύτερους ρυθμούς εκμάθησης και βελτιωμένες ακρίβειες ταξινόμησης. Τα δίκτυα ELU τείνουν να συγκλίνουν πιο γρήγορα λόγω της κατάστασης απενεργοποίησης με ισχυρό θόρυβο και της ευεργετικής μετατόπισης του μέσου όρου των ενεργοποιήσεων προς το μηδέν. Επιπλέον, οι ELU εξαλείφουν την ανάγκη για ομαλοποίηση παρτίδας (batch normalization), ένα ξεχωριστό βήμα που χρησιμοποιείται συχνά για την επίτευξη μέσες μηδενικές ενεργοποιήσεις, απλοποιώντας περαιτέρω την αρχιτεκτονική του δικτύου και μειώνοντας την υπολογιστική πολυπλοκότητα. [77]

2.5.4. Επίπεδα Ομαδοποίησης (Pooling Layers)

Τα επίπεδα ομαδοποίησης είναι ένα κρίσιμο στοιχείο στην αρχιτεκτονική των CNN, που εκτελούν τη διπλή λειτουργία της μείωσης των χωρικών διαστάσεων των εισερχόμενων χαρτών χαρακτηριστικών και της διατήρησης βασικών πληροφοριών. Με τη στρατηγική μείωση της δειγματοληψίας των δεδομένων εισόδου, τα επίπεδα ομαδοποίησης ελαχιστοποιούν τις υπολογιστικές απαιτήσεις και διασφαλίζουν ότι το δίκτυο παραμένει ευαίσθητο στα πιο σημαντικά χαρακτηριστικά της εισόδου, ενισχύοντας την ευρωστία και την αποτελεσματικότητα του CNN.

Η διαδικασία ομαδοποίησης σε ένα CNN αποτελείται κυρίως από δύο στάδια. Πρώτον, η συνάρτηση ομαδοποίησης, όπως η μέγιστη ομαδοποίηση (max pooling) ή η μέση ομαδοποίηση (average pooling), συγκεντρώνει δεδομένα σε τοπικές περιοχές του χάρτη χαρακτηριστικών. Αυτή η συνάνθροιση μπορεί να περιλαμβάνει τη λήψη της μεγαλύτερης τιμής σε μια περιοχή για τη μέγιστη συγκέντρωση ή τον υπολογισμό του μέσου όρου των τιμών για τη μέση ομαδοποίηση. Η λειτουργία ομαδοποίησης περιλαμβάνει την ολίσηση ενός παραθύρου, ή πυρήνα, κατά μήκος του χάρτη χαρακτηριστικών και τη σύνοψη των πληροφοριών μέσα σε αυτό το παράθυρο, συμπιέζοντας ουσιαστικά τα δεδομένα ενώ στόχος είναι να γίνει διατήρηση των πιο κρίσιμων πτυχών τους.



Εικόνα 2.11. Λειτουργία Επιπέδου Ομαδοποίησης (max pooling, average pooling) [78]

Δεύτερον, λαμβάνει χώρα το βήμα της μείωσης της δειγματοληψίας, όπου ένα υποσύνολο των συγκεντρωτικών δεδομένων διατηρείται με βάση έναν προκαθορισμένο βηματισμό, μειώνοντας ουσιαστικά τη διάσταση του χάρτη χαρακτηριστικών. Για παράδειγμα, εάν χρησιμοποιείται ένας βηματισμός δύο, κάθε δεύτερο τμήμα συγκεντρωτικών πληροφοριών διατηρείται ενώ οι υπόλοιπες απορρίπτονται. Αυτό το βήμα είναι κρίσιμο, καθώς μειώνει σημαντικά τον αριθμό των παραμέτρων και το υπολογιστικό φορτίο που κινείται προς τα εμπρός στο δίκτυο.


Η σημασία των επιπέδων αυτών υπερβαίνει την απλή μείωση δεδομένων. Με την αφαίρεση των χαρακτηριστικών που εξάγονται σε συνελκτικά επίπεδα, τα επίπεδα ομαδοποίησης βοηθούν το δίκτυο να επιτύχει αμετάβλητη μετάφραση, επιτρέποντας στο μοντέλο να αναγνωρίζει χαρακτηριστικά ανεξάρτητα από τη θέση τους στο οπτικό πεδίο. Αυτή η ιδιότητα είναι εξαιρετικά σημαντική για το δίκτυο να αναγνωρίζει αντικείμενα σε εικόνες ανεξάρτητα από τις χωρικές τους παραλλαγές.

Η Max pooling, μια από τις πιο ευρέως διαδεδομένες μεθόδους ομαδοποίησης, ευνοείται για την απλότητα και την ικανότητά της να επισημαίνει τα πιο σημαντικά χαρακτηριστικά διατηρώντας τη μέγιστη τιμή σε κάθε παράθυρο του χάρτη χαρακτηριστικών. Αντίθετα, η μέση συγκέντρωση υπολογίζει τον μέσο όρο των τιμών μέσα στο παράθυρο, προσφέροντας μια πιο ολοκληρωμένη σύνοψη των χαρακτηριστικών, αλλά δυνητικά οδηγεί σε απώλεια κρίσιμων πληροφοριών εάν η περιοχή περιέχει πολλές ενεργοποιήσεις χαμηλής έντασης. Είναι η προσεκτική εξισορρόπηση αυτών των χαρακτηριστικών που επιτρέπει στα επίπεδα συγκέντρωσης να συμπυκνώνουν αποτελεσματικά τις πληροφορίες, μειώνοντας έτσι την υπερπροσαρμογή και δίνοντας τη δυνατότητα στο δίκτυο να γενικεύει καλύτερα από τα δεδομένα εκπαίδευσης σε νέες, άορατες εισόδους. [79]

2.5.5. Πλήρως Συνδεδεμένα Επίπεδα (Fully Connected Layers)

Τα πλήρως συνδεδεμένα επίπεδα, γνωστά και ως πυκνό επίπεδο (dense layer), παίζουν έναν απαραίτητο ρόλο στην αρχιτεκτονική του δικτύου. Αυτά τα επίπεδα, τα οποία παραδοσιακά ακολουθούν τα επίπεδα συνέλιξης και ομαδοποίησης, είναι όπου συμβαίνει το «σκεπτόμενο» μέρος του νευρωνικού δικτύου. Κάθε νευρώνας σε ένα πλήρως συνδεδεμένο επίπεδο συνδέεται με κάθε νευρώνα στο προηγούμενο επίπεδο, επιτρέποντας στο δίκτυο να εξετάσει όλα τα χαρακτηριστικά που είχαν μάθει προηγουμένως στο δίκτυο για τη λήψη της τελικής απόφασης ταξινόμησης ή παλινδρόμησης.

Με μαθηματικούς όρους, αν θεωρηθεί ένα πλήρως συνδεδεμένο επίπεδο με N νευρώνες που ακολουθεί ένα επίπεδο με M νευρώνες, τότε δημιουργεί συνδέσεις $N \times M$. Αυτή η πυκνή δομή δικτύου θυμίζει τα παραδοσιακά νευρωνικά δίκτυα και από εκεί προέρχεται ο όρος «πλήρως συνδεδεμένος». Ο επεκτατικός χαρακτήρας αυτών των συνδέσεων σημαίνει ότι εμπλέκεται ένας σημαντικός αριθμός παραμέτρων, που είναι ταυτόχρονα πλεονέκτημα και αδυναμία. Από τη μία πλευρά, αυτή η ολοκληρωμένη συνδεσιμότητα επιτρέπει στο δίκτυο να ενσωματώνει διεξοδικά τις μαθημένες λειτουργίες. Από την άλλη πλευρά, ο τεράστιος αριθμός παραμέτρων μπορεί να οδηγήσει σε αυξημένη υπολογιστική πολυπλοκότητα και αυξημένο κίνδυνο υπερπροσαρμογής.




Εικόνα 2.12. Ένα πλήρως συνδεδεμένο δίκτυο με είσοδο x_1, x_2, x_3 και νευρώνες πυκνού επιπέδου n_1, n_2, n_3, n_4 . [80]

Τα πλήρως συνδεδεμένα επίπεδα είναι όπου ενσωματώνονται και ερμηνεύονται τα χωρικά ιεραρχημένα χαρακτηριστικά που εξάγονται από τα συνελκτικά επίπεδα. Αφού τα συνελκτικά επίπεδα έχουν ανιχνεύσει χαρακτηριστικά και τα επίπεδα συγκέντρωσης έχουν μειωμένη διάσταση (διατηρώντας παράλληλα τις πιο σημαντικές πληροφορίες), τα πλήρως συνδεδεμένα στρώματα συνθέτουν αυτές τις πληροφορίες για να λάβουν περίπλοκες αποφάσεις. Οι νευρώνες εδώ έχουν το πλήρες πλαίσιο των εισόδων, καθιστώντας τους ικανούς να καταγράψουν μοτίβα που κατανέμονται σε ολόκληρο τον χώρο εισόδου.

Ωστόσο, το μειονέκτημα της ύπαρξης ενός τόσο πυκνού επιπέδου είναι ότι εισάγει έναν μεγάλο αριθμό εκπαιδευσιμων παραμέτρων. Για παράδειγμα, εξέχουσες αρχιτεκτονικές όπως το AlexNet [81] και το VGG16 [82] περιέχουν εκατομμύρια παραμέτρους μόνο στα πλήρως συνδεδεμένα επίπεδά τους. Αυτή η βαριά παραμετροποίηση μπορεί να οδηγήσει σε υπερπροσαρμογή, όπου το μοντέλο μαθαίνει πολύ καλά τα δεδομένα εκπαίδευσης, συμπεριλαμβανομένου του θορύβου και των ακραίων τιμών, μειώνοντας την ικανότητά του να γενικεύει σε μη ορατά δεδομένα.

Για να καταπολεμηθεί αυτό, τεχνικές όπως η εγκατάλειψη (Dropout) χρησιμοποιούνται κατά τη διάρκεια της φάσης εκπαίδευσης. Το Dropout απενεργοποιεί τυχαία ένα υποσύνολο νευρώνων στα πλήρως συνδεδεμένα επίπεδα, όπως φαίνεται στην *Εικ. 2.13.*, γεγονός που αναγκάζει το δίκτυο να μάθει πιο ισχυρά χαρακτηριστικά που δεν εξαρτώνται από κανένα μικρό σύνολο νευρώνων. Αυτό μπορεί να βοηθήσει σημαντικά στη μείωση της υπερπροσαρμογής και επίσης στη μείωση των υπολογιστικών απαιτήσεων. [83]



Εικόνα 2.13. Απεικόνιση δικτύου χωρίς τη τεχνική dropout (*no dropout*) και δικτύου με τη τεχνική dropout (*with dropout*) όπου παρατηρείται τυχαία απενεργοποίηση μερικών νευρώνων στα πυκνά πλήρως συνδεδεμένα επίπεδα του δικτύου [84]


2.5.6. Επίπεδο Εξόδου (Output Layer)

Το επίπεδο εξόδου είναι το τερματικό σημείο ενός CNN όπου οι επεξεργασμένες πληροφορίες από τα προηγούμενα επίπεδα καταλήγουν σε ένα οριστικό σύνολο εξόδων. Αυτό το επίπεδο προσαρμόζει τις πληροφορίες που λαμβάνονται από τα επίπεδα συνέλιξης, ομαδοποίησης και πλήρως συνδεδεμένων επιπέδων ώστε να ταιριάζουν στη μορφή που απαιτείται για την εκάστοτε εργασία, είτε πρόκειται για παλινδρόμηση, ταξινόμηση ή ανίχνευση αντικειμένων.

Για εργασίες παλινδρόμησης, πρόβλεψης συνεχών μεταβλητών, το επίπεδο εξόδου μπορεί να αποτελείται από έναν μόνο νευρώνα. Αυτός ο νευρώνας λειτουργεί τυπικά χωρίς συνάρτηση ενεργοποίησης ή χρησιμοποιεί μια γραμμική συνάρτηση ενεργοποίησης για να παράγει μια τιμή που αντιστοιχεί άμεσα στην προβλεπόμενη ποσότητα. Στον τομέα της ανίχνευσης αντικειμένων, η δομή του επιπέδου εξόδου γίνεται πιο περίπλοκη, συχνά περιλαμβάνοντας αρκετούς νευρώνες. Κάθε νευρώνας συσχετίζεται με διαφορετικά χαρακτηριστικά των ανιχνευόμενων αντικειμένων, όπως πιθανότητες κλάσης ή συντεταγμένες πλαισίου οριοθέτησης. Αυτή η διάταξη επιτρέπει στο δίκτυο να αρθρώσει τις διάφορες πτυχές της εργασίας ανίχνευσης μέσα σε ένα ενιαίο διάλυμα εξόδου. Αντίθετα, για εργασίες ταξινόμησης, ιδιαίτερα ταξινόμηση εικόνων, το επίπεδο εξόδου σχεδιάζεται συνήθως ως ένα πυκνό στρώμα με τόσους νευρώνες όσες υπάρχουν κλάσεις για πρόβλεψη. Εδώ, χρησιμοποιείται η λειτουργία ενεργοποίησης softmax. Αυτή η συνάρτηση μετατρέπει τα logit, τις ακατέργαστες προβλέψεις που γίνονται από το τελικό επίπεδο του δικτύου, σε πιθανότητες, εκθέτοντας κάθε logit και στη συνέχεια κανονικοποιώντας αυτές τις τιμές σε όλες τις κλάσεις.

Μαθηματικά, η συνάρτηση softmax εκφράζεται ως:

$$\text{softmax}(x_i) = \frac{e^{x_i}}{\sum_{i=1}^n e^{x_i}}$$



Εικόνα 2.14. Γραφική αναπαράσταση της συνάρτησης softmax [85]

Η συνάρτηση softmax λειτουργεί με την αρχή ότι τονίζει το μεγαλύτερο logit ενώ καταστέλλει τις άλλες, με αποτέλεσμα μια κατανομή πιθανότητας όπου το άθροισμα είναι 1. Αυτό το χαρακτηριστικό την καθιστά ιδιαίτερα κατάλληλη για προβλήματα ταξινόμησης πολλαπλών κλάσεων, όπου κάθε νευρώνας εξόδου αντιπροσωπεύει μια κλάση, και η συνάρτηση softmax εκχωρεί μια πιθανότητα σε καθεμία, υποδεικνύοντας την πιθανότητα η εικόνα εισόδου να ανήκει σε αυτήν την κλάση. [86]

Έχοντας δημιουργήσει μια σταθερή θεωρητική κατανόηση της νόσου του Αλτσχάιμερ και των πλαισίων βαθιάς μάθησης που είναι έτοιμη να φέρει επανάσταση στη διάγνωση και τη μελέτη της, μεταβαίνουμε στην πρακτική εφαρμογή αυτών των εννοιών. Το τμήμα μεθοδολογίας αυτής της εργασίας είναι αφιερωμένο στην περίπλοκη διαδικασία ανάπτυξης και τελειοποίησης ενός εξελιγμένου μοντέλου βαθιάς μάθησης προσαρμοσμένο για την ταξινόμηση εικόνων MRI, ένα κομβικό βήμα στην έρευνα και τη διάγνωση της AD.

Αυτή η φάση της έρευνας είναι όπου η θεωρία συναντά την πράξη, καθώς εφαρμόζονται οι αρχές των τεχνητών νευρωνικών δικτύων σε πραγματικά δεδομένα, πλοηγώντας τις προκλήσεις του αλγοριθμικού σχεδιασμού, της επεξεργασίας δεδομένων και της αξιολόγησης μοντέλων. Τα επόμενα κεφάλαια θα καταγράψουν το ταξίδι από την αρχική απόκτηση δεδομένων μέσω των απαιτήσεων της προεπεξεργασίας, της επιλογής και εφαρμογής της κατάλληλης αρχιτεκτονικής βαθιάς μάθησης, στη σχολαστική βελτιστοποίηση των παραμέτρων που καταλήγει σε ένα μοντέλο ικανό στον εντοπισμό προτύπων ενδεικτικών της νόσου.

3. Μεθοδολογία

Το κεφάλαιο μεθοδολογίας αυτής της εργασίας παρέχει μια λεπτομερή περιγραφή των διαδικασιών και τεχνικών που χρησιμοποιούνται για την ανάπτυξη και την αξιολόγηση ενός μοντέλου βαθιάς μάθησης για την ταξινόμηση των σταδίων της AD χρησιμοποιώντας εικόνες MRI. Αυτό το κεφάλαιο είναι δομημένο ώστε να καθοδηγεί μεθοδικά τον αναγνώστη σε κάθε κρίσιμη φάση της μελέτης, από την αρχική προετοιμασία του συνόλου δεδομένων έως την τελική αξιολόγηση της απόδοσης του μοντέλου.

Αρχικά, επισημαίνεται το υλικό και το λογισμικό που χρησιμοποιήθηκαν στη μελέτη. Η υπολογιστική ρύθμιση υψηλής απόδοσης, συμπεριλαμβανομένου ενός επεξεργαστή AMD Ryzen 5 2600X, 16 GB μνήμης RAM και μιας κάρτας γραφικών NVIDIA GeForce RTX 4070, έπαιξε ιδιαίτερο ρόλο στην ανάπτυξη του μοντέλου. Το περιβάλλον λογισμικού, που υποστηρίζεται από την Python και βασικές βιβλιοθήκες όπως το TensorFlow, το Keras, και το NumPy, παρείχε μια ισχυρή πλατφόρμα για την υλοποίηση μοντέλων.

Έπειτα, το κεφάλαιο εμβαθύνει στην περιγραφή των δεδομένων. Εδώ, περιγράφονται λεπτομερώς οι πηγές, τα χαρακτηριστικά και οι μέθοδοι προεπεξεργασίας του συνόλου δεδομένων εικόνων MRI. Αυτή η ενότητα υπογραμμίζει την ποικιλομορφία και την πολυπλοκότητα των δεδομένων, μαζί με τα συγκεκριμένα βήματα προεπεξεργασίας που έγιναν για την τυποποίηση και προετοιμασία των δεδομένων για αποτελεσματική εκπαίδευση μοντέλων.

Η επόμενη ενότητα για την αρχιτεκτονική του μοντέλου προσφέρει μια ολοκληρωμένη ματιά στη δομή του μοντέλου βαθιάς μάθησης. Εξηγεί το σκεπτικό πίσω από την επιλογή του μοντέλου, τις αρχιτεκτονικές του αποχρώσεις και τις συγκεκριμένες διαμορφώσεις που το καθιστούν κατάλληλο για το έργο της ταξινόμησης εικόνων. Αυτό το μέρος είναι κρίσιμο για την κατανόηση των θεωρητικών θεμελίων του σχεδιασμού του μοντέλου.

Στην εκπαίδευση του μοντέλου, το κεφάλαιο προχωρά στις πρακτικές πτυχές της εφαρμογής του μοντέλου βαθιάς μάθησης. Καλύπτει τη ρύθμιση περιβάλλοντος, τις διαδικασίες εκπαίδευσης, τον συντονισμό υπερπαραμέτρων και τους αλγόριθμους που χρησιμοποιούνται. Αυτή η ενότητα είναι ιδιαίτερα σημαντική για την κατανόηση του τρόπου με τον οποίο το μοντέλο μαθαίνει από το σύνολο δεδομένων και πώς βελτιστοποιείται η απόδοσή του.

Η ενότητα της επικύρωσης του μοντέλου εξετάζει τις τεχνικές και τις μετρήσεις που χρησιμοποιούνται για την επικύρωση του. Εξηγεί πώς δοκιμάστηκε και βελτιώθηκε η απόδοση του μοντέλου κατά τη διαδικασία ανάπτυξης, διασφαλίζοντας την αξιοπιστία και τη στιβαρότητά του.

Η προτελευταία ενότητα, Αξιολόγηση Μοντέλου, παρουσιάζει τα κριτήρια και τις μεθόδους που χρησιμοποιήθηκαν για την αξιολόγηση του τελικού μοντέλου. Εξηγεί τις διάφορες μετρήσεις που χρησιμοποιούνται για την αξιολόγηση της απόδοσης του μοντέλου, όπως η ακρίβεια, η ανάκληση, η βαθμολογία F1 και άλλα. Αυτή η ενότητα είναι κρίσιμη για την κατανόηση του πόσο καλά αποδίδει το μοντέλο σε πρακτικά σενάρια.

Τέλος, το κεφάλαιο πραγματεύεται τους περιορισμούς και τις προκλήσεις που συναντήθηκαν κατά τη διάρκεια της μελέτης. Συζητά με ειλικρίνεια τους περιορισμούς του μοντέλου και του συνόλου δεδομένων, καθώς και τα εμπόδια που συναντήθηκαν κατά τη διάρκεια της έρευνας. Αυτή η ενότητα παρέχει μια ειλικρινή αξιολόγηση των προκλήσεων της μελέτης, προσφέροντας μια ισορροπημένη προοπτική.

3.1. Εξοπλισμός και Λογισμικό

Η εργασία υποστηρίχθηκε από μια ισχυρή υπολογιστική ρύθμιση, η οποία εξασφαλίζει αποτελεσματικό χειρισμό και επεξεργασία των σύνθετων εργασιών βαθιάς μάθησης που εμπλέκονται. Ο πυρήνας των υπολογιστικών πόρων ήταν ένας προσωπικός υπολογιστής εξοπλισμένος με επεξεργαστή AMD Ryzen 5 2600X Six-Core Processor, χρονισμένο στα 3,60 GHz. Αυτός ο επεξεργαστής, γνωστός για τις υψηλές επιδόσεις του, ιδιαίτερα σε εφαρμογές multi-threaded, έπαιξε καθοριστικό ρόλο στη διαχείριση του υπολογιστικού φορτίου. Συμπληρώνοντας τον επεξεργαστή, το σύστημα εγκαταστάθηκε με 16,0 GB μνήμης RAM, διευκολύνοντας τον αποτελεσματικό χειρισμό δεδομένων και τις δυνατότητες πολλαπλών εργασιών, σημαντική για διαδικασίες βαθιάς μάθησης που συχνά απαιτούν μνήμη [87]. Η συμπερίληψη μιας κάρτας γραφικών NVIDIA GeForce RTX 4070, είναι αξιοσημείωτο χαρακτηριστικό της υπολογιστικής εγκατάστασης. Αυτή η GPU, γνωστή για την προηγμένη αρχιτεκτονική της και την υψηλή επεξεργαστική της ισχύ, έπαιξε καθοριστικό ρόλο στην σημαντική επιτάχυνση της εκπαίδευσης και της αξιολόγησης των μοντέλων βαθιάς μάθησης. Η ικανότητα της GPU αξιοποιήθηκε περαιτέρω μέσω μιας ποικιλίας προγραμμάτων drivers και εργαλείων NVIDIA, όπως το CUDA Development and Runtime έκδοση 11.8, το CUDA Toolkit 12.3 και διάφορα άλλα στοιχεία του οικοσυστήματος NVIDIA. Αυτά τα εργαλεία επέτρεψαν τη βελτιστοποιημένη χρήση της GPU, αξιοποιώντας το πλήρες δυναμικό της για εργασίες παράλληλης επεξεργασίας που είναι εγγενείς στη βαθιά μάθηση.

Όσον αφορά το λογισμικό, χρησιμοποιήθηκε Python έκδοσης 3.10.12, μια γλώσσα προγραμματισμού που φημίζεται για την απλότητα και την αποτελεσματικότητά της στο χειρισμό εργασιών της επιστήμης δεδομένων. Το περιβάλλον ανάπτυξης εμπλουτίστηκε περαιτέρω με το πρόγραμμα Microsoft Visual Studio, έναν ευέλικτο και ισχυρό επεξεργαστή κώδικα και το WSL Ubuntu, παρέχοντας μια διεπαφή και ένα σύνολο εργαλείων που μοιάζει με Unix σε μια πλατφόρμα Windows. Οι βασικές επεκτάσεις που είναι εγκατεστημένες στο Visual Studio, όπως το Jupyter, η Python και διάφορα εργαλεία ανάπτυξης και μορφοποίησης Python, διευκόλυναν μια βελτιωμένη εμπειρία κωδικοποίησης, βελτιώνοντας την παραγωγικότητα και την ποιότητα του κώδικα.

Το μοντέλο βαθιάς μάθησης αναπτύχθηκε χρησιμοποιώντας το TensorFlow, μια ολοκληρωμένη βιβλιοθήκη ανοιχτού κώδικα για μηχανική μάθηση και νευρωνικά δίκτυα. Η ικανότητα του TensorFlow να αξιοποιεί τις δυνατότητες της GPU μέσω της MirroredStrategy [88] ήταν ένας βασικός παράγοντας για την επίτευξη αποτελεσματικής εκπαίδευσης μοντέλων. Η βάση κώδικα ενσωμάτωσε επίσης άλλες βιβλιοθήκες όπως η Keras για την κατασκευή και εκπαίδευση μοντέλων νευρωνικών δικτύων, οι NumPy και Pandas για χειρισμό δεδομένων, OpenCV για επεξεργασία εικόνας και Matplotlib και Seaborn για οπτικοποίηση δεδομένων. Οι μετρήσεις του Scikit-learn χρησιμοποιήθηκαν για την αξιολόγηση του μοντέλου, παρέχοντας μια σειρά από συναρτήσεις για την αξιολόγηση της απόδοσης.

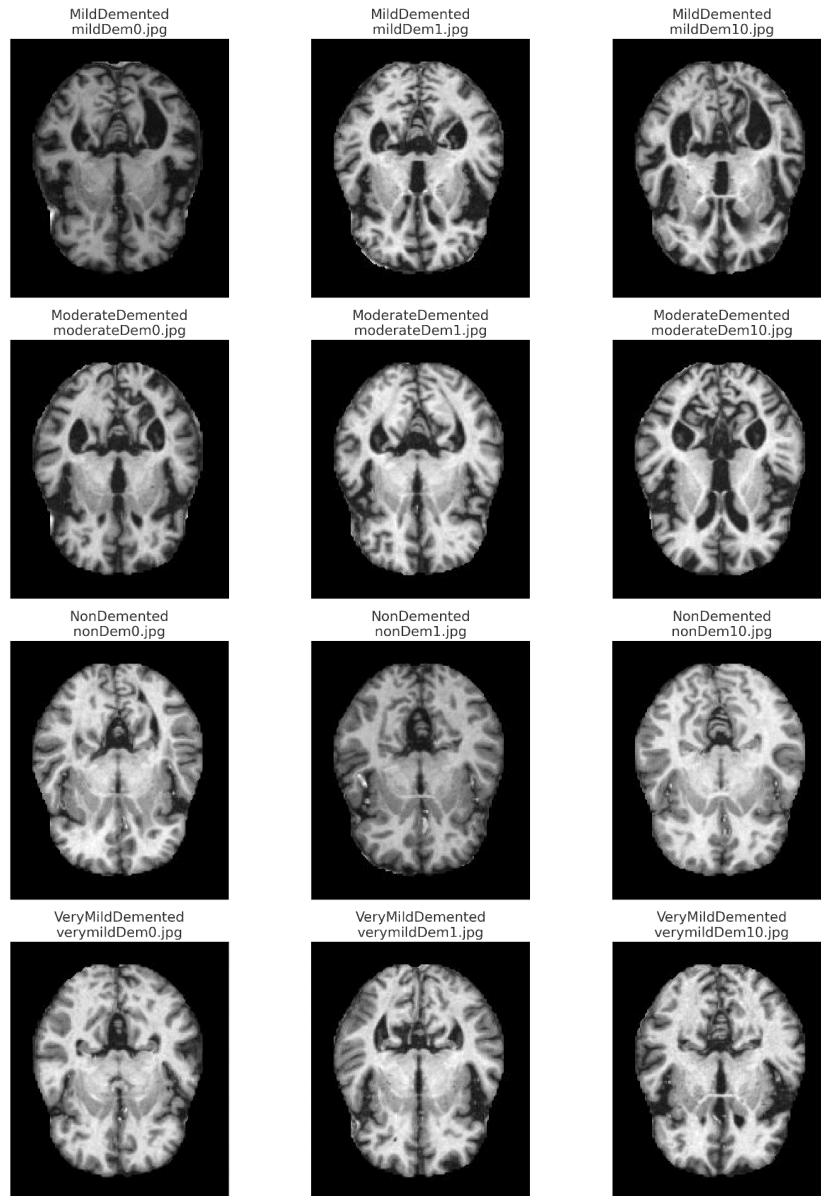
Κατά τη διάρκεια της φάσης εκπαίδευσης του μοντέλου, επικυρώθηκε η διαμόρφωση του συστήματος για χρήση της GPU, όπως υποδεικνύεται από τις καταχωρήσεις καταγραφής TensorFlow. Αυτή η ρύθμιση επιβεβαίωσε την αποτελεσματική κατανομή των πόρων της GPU, βελτιστοποιώντας τη διαδικασία εκπαίδευσης και αξιολόγησης του μοντέλου. Το αρχείο καταγραφής τόνισε επίσης την ικανότητα του συστήματος να χειρίζεται τις απαιτήσεις του TensorFlow, διασφαλίζοντας μια απρόσκοπτη και αποτελεσματική υπολογιστική ροή εργασίας.

3.2. Χαρακτηριστικά των Δεδομένων

Το σύνολο δεδομένων που στηρίζει αυτήν την εργασία αποτελείται από προεπεξεργασμένες εικόνες MRI και έχει δημοσιευθεί στην ιστοσελίδα Kaggle από τους Sachin et al. (2022) [116]. Έχουν συλλεχθεί σχολαστικά από μια ποικιλία αξιόπιστων πηγών, συμπεριλαμβανομένων των Alzheimer's Disease Neuroimaging Initiative (ADNI) [89], Alzheimer's.net [90], Kaggle [91], IEEE Xplore publications [92], Data.gov [93], Nature publications [94] και CORDIS [95] από τα ερευνητικά αποτελέσματα της ΕΕ. Αυτή η ποικιλόμορφη συλλογή εξασφαλίζει μια ολοκληρωμένη αναπαράσταση του θέματος.

Ένα βασικό χαρακτηριστικό του συνόλου δεδομένων είναι η κατηγοριοποίησή του σε τέσσερις διακριτές κατηγορίες, συγκεκριμένα MildDemented, ModerateDemented, NonDemented και VeryMildDemented. Αυτή η ταξινόμηση διευκολύνει μια λεπτή κατανόηση της εξέλιξης του AD, η οποία είναι πρωταρχικής σημασίας για τη μελέτη. Το σετ εκπαίδευσης περιλαμβάνει συνολικά 5121 εικόνες, που διανέμονται ως 717 εικόνες στο MildDemented (ήπια άνοια), 52 σε ModerateDemented (μέτρια άνοια), 2560 σε NonDemented (χωρίς άνοια) και 1792 σε VeryMildDemented (πολύ ήπια άνοια). Το σετ ελέγχου περιλαμβάνει 1279 εικόνες, με 179 MildDemented, 12 ModerateDemented, 640 NonDemented και 448 VeryMildDemented. Αυτή η κατανομή υποδηλώνει μια σημαντική ανισορροπία κατηγορίας, ιδιαίτερα αισθητή στην κατηγορία ModerateDemented, η οποία θέτει μοναδικές προκλήσεις και εκτιμήσεις για την εκπαίδευση και την ακρίβεια αξιολόγησης του μοντέλου. Κάθε εικόνα στο σύνολο δεδομένων έχει ομοιόμορφο μέγεθος 176x208 pixel, που παρουσιάζεται σε κλίμακα του γκρι. Αυτή η ομοιομορφία στις διαστάσεις και το συνδυασμό χρωμάτων είναι πλεονεκτική, ελαχιστοποιώντας την ανάγκη για εκτεταμένη προεπεξεργασία για την τυποποίηση των εικόνων για αποτελεσματική εκπαίδευση και αξιολόγηση μοντέλων. Οι εικόνες είναι όλες σε μορφή JPEG, μια κοινή και βολική μορφή για χειρισμό και επεξεργασία στο πλαίσιο εργασιών βαθιάς μάθησης.

ΔΙΑΓΝΩΣΗ ΤΗΣ ΝΟΣΟΥ ΤΟΥ ΑΛΤΣΧΑΙΜΕΡ ΜΕ ΧΡΗΣΗ ΒΑΘΙΑΣ ΜΑΘΗΣΗΣ ΚΑΙ ΑΝΑΛΥΣΗΣ ΕΙΚΟΝΑΣ



Εικόνα 3.1. Δείγματα εικόνων από κάθε κατηγορία

Η επιλογή και η δομή αυτού του συνόλου δεδομένων είναι καθοριστικής σημασίας για τον πρωταρχικό στόχο αυτής της εργασίας. Τα εγγενή χαρακτηριστικά αυτού του συνόλου δεδομένων, συμπεριλαμβανομένης της ποικιλομορφίας, της κατηγοριοποίησης και της ομοιομορφίας στις ιδιότητες της εικόνας, παρέχουν μια ισχυρή βάση για την επίτευξη αυτού του στόχου. Ωστόσο, η ανισορροπία τάξης που παρατηρείται απαιτεί προσεκτική εξέταση στη διαδικασία εκπαίδευσης του μοντέλου.

3.3. Προετοιμασία των δεδομένων για την εκπαίδευση του μοντέλου

Η διαδικασία προετοιμασίας δεδομένων για την εκπαίδευση του μοντέλου είναι μια θεμελιώδης πτυχή της μεθοδολογίας, σημαντική για την επιτυχή εκπαίδευση και αξιολόγηση του μοντέλου βαθιάς μάθησης. Αυτή η ενότητα περιγράφει τα βήματα που έγιναν για την προετοιμασία των μεταβλητών και την προετοιμασία των συνόλων δεδομένων εκπαίδευσης και επικύρωσης.

Προετοιμασία σετ δεδομένων εκπαίδευσης και επικύρωσης

```
Autotune = tf.data.experimental.AUTOTUNE
batch_size = 16 * strategy.num_replicas_in_sync
img_size = [176, 208]
epochs = 150

train_dataset = tf.keras.preprocessing.image_dataset_from_directory(
    "/home/tsopermon/projects/AlzheimersDataset/train",
    validation_split=0.2,
    subset="training",
    seed=1337,
    image_size=img_size,
    batch_size=batch_size
)

val_dataset = tf.keras.preprocessing.image_dataset_from_directory(
    "/home/tsopermon/projects/AlzheimersDataset/train",
    validation_split=0.2,
    subset="validation",
    seed=1337,
    image_size=img_size,
    batch_size=batch_size
)

class_names = ['MildDementia', 'ModerateDementia', 'NonDementia', 'VeryMildDementia']
train_dataset.class_names = class_names
val_dataset.class_names = class_names
num_classes = len(class_names)

def one_hot_label(image, label):
    label = tf.one_hot(label, num_classes)
    return image, label

train_dataset = train_dataset.map(one_hot_label, num_parallel_calls=Autotune)
val_dataset = val_dataset.map(one_hot_label, num_parallel_calls=Autotune)

train_dataset = train_dataset.cache().prefetch(buffer_size=Autotune)
val_dataset = val_dataset.cache().prefetch(buffer_size=Autotune)
```

Ξεκινώντας τη διαδικασία, ρυθμίζονται βασικές μεταβλητές για τη βελτιστοποίηση του χειρισμού δεδομένων και της εκπαίδευσης μοντέλων. Η χρήση του `tf.data.experimental.AUTOTUNE` επιτρέπει στο TensorFlow να προσδιορίζει αυτόματα τον πιο αποτελεσματικό αριθμό στοιχείων για προανάκτηση, βελτιώνοντας την απόδοση εισόδου/εξόδου. Αυτή η δυνατότητα είναι ιδιαίτερα σημαντική για την αποτελεσματική διαχείριση μεγάλων συνόλων δεδομένων. Το `batch_size` (μέγεθος παρτίδας) υπολογίζεται “στρατηγικά” ως 16 φορές τον αριθμό των αντιγράφων στη στρατηγική συγχρονισμού. Σε ένα καταναμημένο πλαίσιο εκπαίδευσης, αυτή η προσέγγιση βοηθά στη διατήρηση ενός συνεπούς καθολικού μεγέθους παρτίδας σε διαφορετικές GPU, ένας σημαντικός παράγοντας για ομοιόμορφη εκπαίδευση μοντέλων και απόδοση. Η μεταβλητή `img_size`, που έχει οριστεί σε [176, 208], τυποποιεί τις διαστάσεις των εικόνων, ένα απαραίτητο βήμα για να διασφαλιστεί ότι όλες οι εικόνες που τροφοδοτούνται στα στρώματα του CNN έχουν ομοιόμορφο μέγεθος. Τέλος, τα `epochs` ορίζονται σε 150, ορίζοντας τον συνολικό αριθμό των επαναλήψεων που θα κάνει ο αλγόριθμος εκμάθησης σε ολόκληρο το σύνολο δεδομένων εκπαίδευσης. Αυτή η διαδικασία ορίζει το βάθος και τη διάρκεια εκπαίδευσης του μοντέλου.

Η οργάνωση των συνόλων δεδομένων εκπαίδευσης και επικύρωσης εκτελείται σχολαστικά για να παρέχει στο μοντέλο καλά οργανωμένα και υψηλής ποιότητας δεδομένα. Η συνάρτηση `tf.keras.preprocessing.image_dataset_from_directory` χρησιμοποιείται για την αποτελεσματική φόρτωση εικόνων από την καθορισμένη θέση αρχείων. Το σύνολο δεδομένων χωρίζεται σε σύνολα εκπαίδευσης και επικύρωσης, με την παράμετρο `validation_split` να έχει οριστεί σε 0,2, δεσμεύοντας το 20% των δεδομένων για σκοπούς επικύρωσης. Η παράμετρος `subset` κατηγοριοποιεί τα δεδομένα σε `training` για το σύνολο δεδομένων εκπαίδευσης και `validation` για το σύνολο δεδομένων επικύρωσης. Αυτός ο διαχωρισμός είναι απαραίτητος για να διασφαλιστεί ότι το μοντέλο εκπαιδεύεται και επικυρώνεται σε διαφορετικά σύνολα δεδομένων, παρέχοντας μια πιο ακριβή μέτρηση της απόδοσής του. Η συνέπεια και η επαναληψιμότητα στη διαδικασία διαχωρισμού διατηρούνται με τον καθορισμό ενός `seed`, το οποίο διασφαλίζει ότι η διαίρεση μεταξύ των συνόλων εκπαίδευσης και επικύρωσης παραμένει σταθερή σε διάφορες διαδρομές. Το μέγεθος των εικόνων παραμένει στις προκαθορισμένες διαστάσεις από το `img_size`, τυποποιώντας τις σε 176x208 pixel. Επιπλέον, ορίζεται το `batch_size` για τη φόρτωση εικόνων, προσδιορίζοντας τον αριθμό των εικόνων που θα περάσουν μέσω του δικτύου κατά τη διάρκεια της εκπαίδευσης.

Τα ονόματα των κλάσεων ορίζονται χειροκίνητα, περιλαμβάνοντας τις διαφορετικές κλάσεις που υπάρχουν στο σύνολο δεδομένων. Αυτή η μη αυτόματη ρύθμιση χρησιμοποιείται αργότερα για την επισήμανση οπτικοποιήσεων και την ερμηνεία των αποτελεσμάτων του μοντέλου. Εκχωρούνται στο χαρακτηριστικό `class_names` των συνόλων δεδομένων εκπαίδευσης και επικύρωσης, βελτιώνοντας τη σαφήνεια και την ευκολία αναφοράς.

Οι ετικέτες `labels` στα σύνολα δεδομένων εκπαίδευσης και επικύρωσης μετατρέπονται σε κωδικοποιημένη μορφή «one-hot», ορίζοντας και χρησιμοποιώντας τη συνάρτηση `one_hot_label`. Η κωδικοποίηση «one-hot» είναι μια τυπική πρακτική για εργασίες ταξινόμησης πολλαπλών κλάσεων σε νευρωνικά δίκτυα, καθώς μετατρέπει τις κατηγορικές ετικέτες σε μια μορφή που είναι πιο κατάλληλη για μοντέλα ταξινόμησης. Η παράμετρος `num_parallel_calls` σε αυτήν τη μέθοδο έχει οριστεί σε `Autotune`, επιτρέποντας στο TensorFlow να προσαρμόζει δυναμικά τον αριθμό των παράλληλων λειτουργιών κατά τη διαδικασία χαρτογράφησης (mapping), βελτιστοποιώντας έτσι την απόδοση.

Επιπλέον, τόσο τα σύνολα δεδομένων εκπαίδευσης όσο και επικύρωσης υποβάλλονται σε λειτουργίες `cache()` και `prefetch()`. Η μέθοδος `cache()` διατηρεί τις εικόνες στη μνήμη μετά την αρχική φόρτωσή τους από το δίσκο κατά το πρώτο «epoch». Αυτό επιταχύνει την εκπαίδευση, καθώς τα δεδομένα δεν χρειάζεται να διαβάζονται από το δίσκο στα επόμενα «epochs». Η μέθοδος `prefetch()`, από την άλλη πλευρά, επικαλύπτει την προεπεξεργασία δεδομένων και την εκτέλεση του μοντέλου κατά την εκπαίδευση. Προετοιμάζει επόμενες παρτίδες «batches» δεδομένων κατά την επεξεργασία της τρέχουσας παρτίδας, μειώνοντας έτσι τον χρόνο που αφιερώνει το μοντέλο αναμένοντας δεδομένα. Το `buffer_size` για την προανάκτηση καθορίζεται σε `Autotune`, επιτρέποντας στο TensorFlow να βελτιστοποιεί αυτόματα αυτήν την παράμετρο με βάση τις δυνατότητες και τον φόρτο εργασίας του συστήματος.

3.4. Αρχιτεκτονική Μοντέλου

Η αρχιτεκτονική του μοντέλου βαθιάς μάθησης σε αυτή τη μελέτη έχει σχεδιαστεί περίπλοκα για να ταξινομεί τα στάδια της AD χρησιμοποιώντας εικόνες

MRI. Το μοντέλο αξιοποιεί μια σειρά συνελκτικών, ενεργοποίησης, συγκέντρωσης, κανονικοποίησης και πυκνών επιπέδων, καθένα από τα οποία παίζει σημαντικό ρόλο στην εξαγωγή και ερμηνεία χαρακτηριστικών από τις εικόνες εισόδου. Αυτή η ενότητα διευκρινίζει την αρχιτεκτονική του μοντέλου και τα λειτουργικά τμήματα που το αποτελούν.

Συνάρτηση Συνελκτικού μπλοκ

```
def conv_block(filters, activation):
    block = tf.keras.Sequential()
    block.add(SeparableConv2D(filters, 3, padding='same'))
    if activation == 'leaky_relu':
        block.add(LeakyReLU(alpha=0.01))
    elif activation == 'prelu':
        block.add(PReLU())
    else:
        block.add(tf.keras.layers.Activation(activation))
    block.add(SeparableConv2D(filters, 3, padding='same'))
    if activation == 'leaky_relu':
        block.add(LeakyReLU(alpha=0.01))
    elif activation == 'prelu':
        block.add(PReLU())
    else:
        block.add(tf.keras.layers.Activation(activation))
    block.add(BatchNormalization())
    block.add(MaxPooling2D())
    return block
```

Το μοντέλο, εμπνευσμένο από το μοντέλο της Jang et al., 2021 [96], χρησιμοποιεί συναρτήσεις `conv_block`, οι οποίες είναι ουσιαστικά ακολουθίες συνελκτικών επιπέδων. Κάθε `conv_block` αποτελείται από δύο επίπεδα `SeparableConv2D`, το καθένα ακολουθούμενο από ένα επίπεδο ενεργοποίησης και ένα επίπεδο `BatchNormalization`. Η χρήση του `SeparableConv2D`, μιας μορφής διαχωρίσιμης σε βάθος συνέλιξης, είναι μια στρατηγική επιλογή για τη μείωση της πολυπλοκότητας και του υπολογιστικού κόστους του μοντέλου χωρίς να διακυβεύεται η ικανότητα εκμάθησης αναπαραστάσεων λεπτομερών χαρακτηριστικών. Αυτά τα επίπεδα εκτελούν συνελίξεις χωριστά σε κάθε κανάλι της εισόδου, ακολουθούμενη από μια σημειακή συνέλιξη που αναμιγνύει αυτά τα κανάλια, άρα είναι πιο αποτελεσματικά από τις παραδοσιακές συνελίξεις. Τα επίπεδα ενεργοποίησης σε αυτά τα μπλοκ είναι δυναμικά, επιτρέποντας τη χρήση διαφορετικών συναρτήσεων ενεργοποίησης όπως `LeakyReLU`, `PReLU` ή τα τυπικά `relu` και `elu`. Αυτή η ευελιξία είναι μεγάλης σημασίας για τη διερεύνηση του τρόπου με τον οποίο οι διαφορετικές λειτουργίες ενεργοποίησης επηρεάζουν τη μάθηση και την απόδοση του μοντέλου. Η συμπερίληψη του `BatchNormalization` μετά από κάθε συνελκτική λειτουργία βοηθά στη σταθεροποίηση και την επιτάχυνση της εκπαιδευτικής διαδικασίας κανονικοποιώντας τις εισόδους κάθε επιπέδου. Κάθε συνελκτικό μπλοκ ολοκληρώνεται με ένα επίπεδο `MaxPooling2D`, το οποίο μειώνει τις χωρικές διαστάσεις της εξόδου από τα προηγούμενα επίπεδα. Αυτή η λειτουργία ομαδοποίησης βοηθά στη μείωση του αριθμού των παραμέτρων και των υπολογισμών στο δίκτυο, ελέγχοντας έτσι την υπερπροσαρμογή και ενισχύοντας την ικανότητα γενίκευσης του μοντέλου.

Συνάρτηση Πυκνού (Dense) μπλοκ

```
def dense_block(units, dropout_rate, activation):
    block = tf.keras.Sequential()
    block.add(Dense(units))
```

```
if activation == 'prelu':  
    block.add(PReLU())  
else:  
    block.add(tf.keras.layers.Activation(activation))  
block.add(BatchNormalization())  
block.add(Dropout(dropout_rate))  
return block
```

Το μοντέλο ενσωματώνει επίσης συναρτήσεις `dense_block`, οι οποίες αποτελούνται από πυκνά επίπεδα που ακολουθούνται από ένα επίπεδο ενεργοποίησης, ένα επίπεδο `BatchNormalization` και ένα επίπεδο `Dropout`. Τα πυκνά επίπεδα, ή τα πλήρως συνδεδεμένα επίπεδα, παίζουν κρίσιμο ρόλο στην εκτέλεση εργασιών ταξινόμησης, καθώς μαθαίνουν μη γραμμικούς συνδυασμούς των χαρακτηριστικών υψηλού επιπέδου που εξάγονται από τα συνελκτικά στρώματα. Η λειτουργία ενεργοποίησης σε αυτά τα πυκνά μπλοκ, παρόμοια με τα συνελκτικά μπλοκ, μπορεί να ποικίλει. Το επίπεδο «BatchNormalization» κανονικοποιεί την έξοδο από το πυκνό στρώμα, ενώ το επίπεδο «Dropout» ρίχνει τυχαία ένα ποσοστό των νευρώνων κατά τη διάρκεια της προπόνησης. Αυτός ο ρυθμός εγκατάλειψης, που ορίζεται μέσα στα πυκνά μπλοκ, είναι καθοριστικός για την πρόληψη της υπερπροσαρμογής διασφαλίζοντας ότι το μοντέλο δεν βασίζεται πολύ σε κάποιο συγκεκριμένο σύνολο νευρώνων. Η λειτουργία ενεργοποίησης σε αυτά τα πυκνά (dense) μπλοκ, παρόμοια με τα συνελκτικά μπλοκ, μπορεί να ποικίλει. Το επίπεδο `BatchNormalization` κανονικοποιεί την έξοδο από το πυκνό επίπεδο, ενώ το επίπεδο `Dropout` ρίχνει τυχαία ένα ποσοστό των νευρώνων κατά τη διάρκεια της εκπαίδευσης. Αυτός ο ρυθμός εγκατάλειψης (dropout), που ορίζεται μέσα στα πυκνά μπλοκ, είναι καθοριστικός για την πρόληψη της υπερπροσαρμογής διασφαλίζοντας ότι το μοντέλο δεν βασίζεται πολύ σε κάποιο συγκεκριμένο σύνολο νευρώνων.


Το μοντέλο συγκαλείται χρησιμοποιώντας τη συνάρτηση `build_model`. Ξεκινά με ένα επίπεδο `Input` που καθορίζει το σχήμα των εικόνων εισόδου. Στη συνέχεια, το μοντέλο προσθέτει μια σειρά συνελκτικών και ομαδοποιημένων επιπέδων, διάσπαρτα με συναρτήσεις ενεργοποίησης. Ακολουθεί η υλοποίηση των συναρτήσεων `conv_block` και `dense_block`, οι οποίες είναι στρατηγικά εφαρμοσμένες για να δημιουργήσουν ένα βαθύ δίκτυο ικανό να καταγράφει πολύπλοκα μοτίβα στα δεδομένα. Το μοντέλο ολοκληρώνεται με ένα τελικό πυκνό επίπεδο με λειτουργία ενεργοποίησης softmax. Αυτό το επίπεδο εξάγει μια κατανομή πιθανότητας στις διάφορες κατηγορίες, επιτρέποντας την ταξινόμηση των εικόνων εισόδου σε ένα από τα στάδια της AD.

Η αρχιτεκτονική αυτού του μοντέλου είναι ένα εξελιγμένο μείγμα διαφόρων τύπων επιπέδων, καθένα από τα οποία συνεισφέρει μοναδικά στην ικανότητα του μοντέλου να μαθαίνει από τα πολύπλοκα μοτίβα που υπάρχουν στις εικόνες MRI. Η προσεκτική διάταξη των συνελκτικών και πυκνών μπλοκ, μαζί με την επιλογή των συναρτήσεων ενεργοποίησης και των τεχνικών τακτοποίησης, υποστηρίζουν την ικανότητα του μοντέλου να εκτελεί ακριβή και αποτελεσματική ταξινόμηση. Η χρήση χωριστών συνελίξεων και η κανονικοποίηση παρτίδας (batch normalization) αντικατοπτρίζει μια στοχαστική προσέγγιση για την οικοδόμηση ενός μοντέλου που δεν είναι μόνο ισχυρό από την άποψη της ικανότητας εκμάθησης αλλά και αποτελεσματικό από την άποψη της χρήσης υπολογιστικών πόρων. Η αρχιτεκτονική του μοντέλου έχει σχεδιαστεί για να εμβαθύνει στις περίπλοκες δομές των εικόνων MRI, εξάγοντας και ερμηνεύοντας χαρακτηριστικά σε διάφορα επίπεδα αφαίρεσης. Ο συνδυασμός διαχωριζόμενων κατά βάθος συνελίξεων και πλήρως συνδεδεμένων επιπέδων επιτρέπει στο μοντέλο να διακρίνει λεπτές παραλλαγές στις εικόνες που είναι ενδεικτικές διαφορετικών σταδίων της AD. Αυτή η ικανότητα ενισχύεται

περαιτέρω από τη δυναμική χρήση των συναρτήσεων ενεργοποίησης, η οποία εισάγει τη μη γραμμικότητα στο δίκτυο, επιτρέποντάς του να καταγράψει σύνθετες σχέσεις στα δεδομένα.

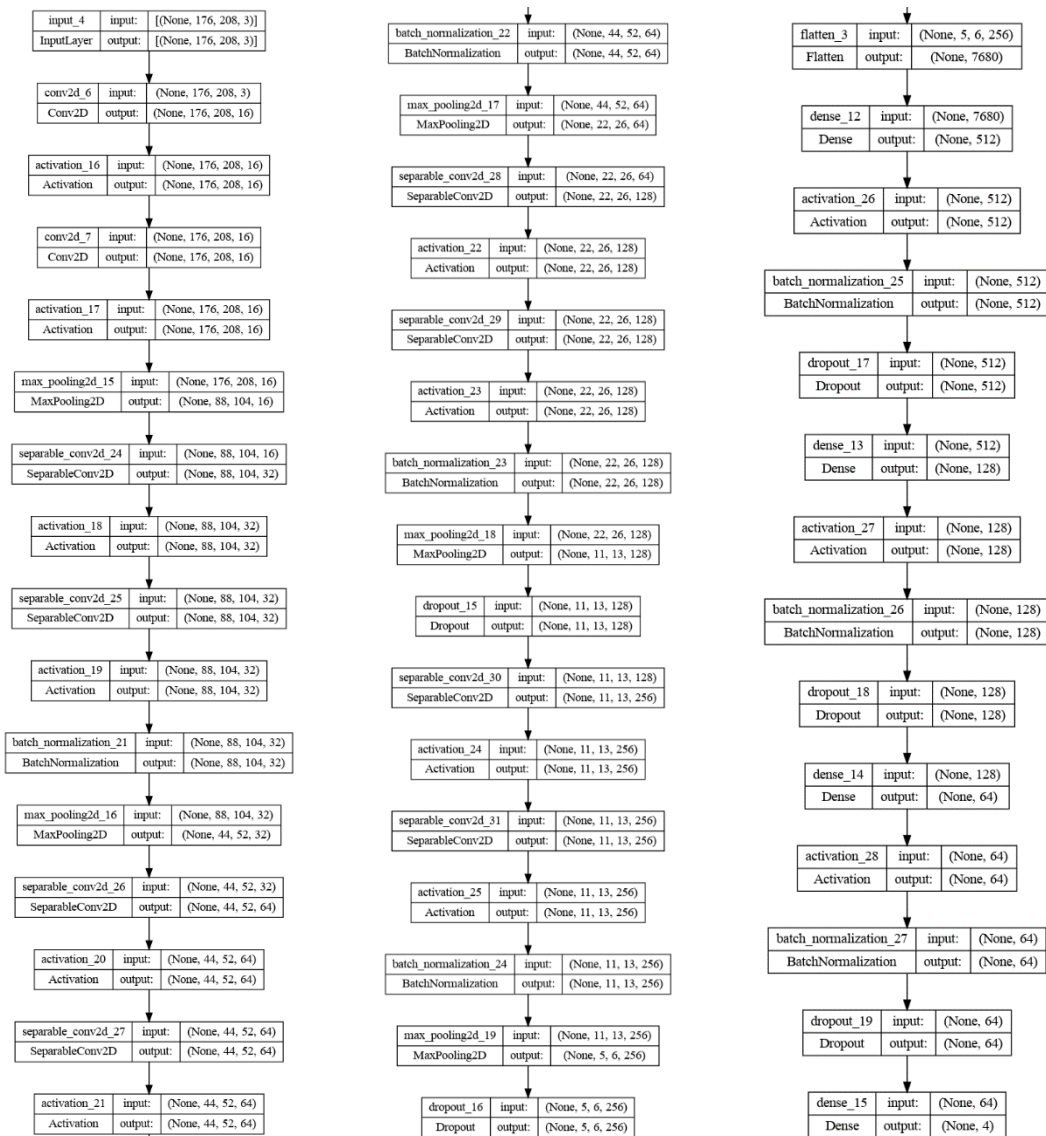
Συνάρτηση Κατασκευής Μοντέλου

```
def build_model(activation):
    model = tf.keras.Sequential()
    model.add(Input(shape=(176, 208, 3)))
    model.add(Conv2D(16, 3, padding='same'))
    if activation == 'leaky_relu':
        model.add(LeakyReLU(alpha=0.01))
    elif activation == 'prelu':
        model.add(PReLU())
    else:
        model.add(tf.keras.layers.Activation(activation))
    model.add(Conv2D(16, 3, padding='same'))
    if activation == 'leaky_relu':
        model.add(LeakyReLU(alpha=0.01))
    elif activation == 'prelu':
        model.add(PReLU())
    else:
        model.add(tf.keras.layers.Activation(activation))
    model.add(MaxPooling2D())
    model.add(conv_block(32, activation))
    model.add(conv_block(64, activation))
    model.add(conv_block(128, activation))
    model.add(Dropout(0.2))
    model.add(conv_block(256, activation))
    model.add(Dropout(0.2))
    model.add(Flatten())
    model.add(dense_block(512, 0.7, activation))
    model.add(dense_block(128, 0.5, activation))
    model.add(dense_block(64, 0.3, activation))
    model.add(Dense(num_classes, activation='softmax'))
    return model
```



Εικόνα 3.2. Οπτικοποίηση Μοντέλου με χρήση `visualkeras.layered_view`

ΔΙΑΓΝΩΣΗ ΤΗΣ ΝΟΣΟΥ ΤΟΥ ΑΛΤΣΧΑΙΜΕΡ ΜΕ ΧΡΗΣΗ ΒΑΘΙΑΣ ΜΑΘΗΣΗΣ ΚΑΙ ΑΝΑΛΥΣΗΣ ΕΙΚΟΝΑΣ



Εικόνα 3.3. Οπτικοποίηση Μοντέλου με χρήση συνάρτησης `plot_model`

3.5. Εκπαίδευση Μοντέλου

Η φάση εκπαίδευσης του μοντέλου είναι μια κρίσιμη διαδικασία όπου το μοντέλο μαθαίνει να ταξινομεί τα στάδια της AD από εικόνες MRI. Αυτή η φάση περιλαμβάνει πολλά βήματα και διαμορφώσεις που είναι βασικές για την αποτελεσματική εκμάθηση και απόδοση του μοντέλου.

3.5.1. Σύνταξη Μοντέλου

Πριν από την εκπαίδευση, το μοντέλο συντάσσεται. Αυτό το βήμα περιλαμβάνει τον καθορισμό του βελτιστοποιητή (optimizer), της συνάρτησης απώλειας και των μετρήσεων που χρησιμοποιούνται για την καθοδήγηση και την αξιολόγηση της διαδικασίας εκμάθησης του μοντέλου. Ο βελτιστοποιητής Adam επιλέχθηκε για την αποτελεσματικότητά του στον χειρισμό αραιών κλίσεων και την προσαρμοστικότητα σε διαφορετικές ρυθμίσεις προβλημάτων. Η συνάρτηση απώλειας που χρησιμοποιείται είναι η κατηγορική διασταυρούμενη εντροπία (categorical cross entropy), η οποία είναι τυπική για εργασίες ταξινόμησης πολλών

κατηγοριών. Αυτή η συνάρτηση απώλειας μετρά τη διαφορά μεταξύ της προβλεπόμενης κατανομής πιθανοτήτων και της πραγματικής κατανομής των κλάσεων. Το μοντέλο χρησιμοποιεί επίσης μια μέτρηση AUC (Area Under the ROC Curve), η οποία είναι απαραίτητη για την αξιολόγηση της απόδοσης του μοντέλου σε ένα πλαίσιο ταξινόμησης, ιδιαίτερα χρήσιμο σε μη ισορροπημένα σύνολα δεδομένων.

3.5.2. Προγραμματισμός Ρυθμού Μάθησης

Η διαδικασία εκπαίδευσης ενσωματώνει έναν προγραμματιστή ρυθμού εκμάθησης που ορίζεται από τη συνάρτηση `exponential_decay_fn``.

```
def exponential_decay(lr0, s):  
    def exponential_decay_fn(epoch):  
        return lr0 * 0.1**(epoch / s)  
    return exponential_decay_fn  
exponential_decay_fn = exponential_decay(0.01, 20)  
lr_scheduler = tf.keras.callbacks.LearningRateScheduler(exponential_decay_fn)
```

Αυτός ο χρονο-προγραμματιστής προσαρμόζει τον ρυθμό εκμάθησης κατά τη διάρκεια της εκπαίδευσης, ακολουθώντας μια προσέγγιση εκθετικής παρακμής. Ο αρχικός ρυθμός εκμάθησης ορίζεται υψηλός και σταδιακά μειώνεται, επιτρέποντας στο μοντέλο να κάνει μεγαλύτερες ενημερώσεις στα βάρη αρχικά και πιο λεπτές προσαρμογές καθώς προχωρά η εκπαίδευση. Αυτή η στρατηγική βοηθά στη σύγκλιση σε ένα πιο ακριβές μοντέλο ταχύτερα και πιο αποτελεσματικά.

3.5.3. Επανακλήσεις

Πολλές επανακλήσεις χρησιμοποιούνται για τη βελτίωση της εκπαιδευτικής διαδικασίας. Η επανάκληση `ModelCheckpoint`` αποθηκεύει την καλύτερη έκδοση του μοντέλου με βάση την απόδοση στα δεδομένα επικύρωσης, διασφαλίζοντας ότι το καλύτερο μοντέλο διατηρείται ακόμα και αν η διαδικασία εκπαίδευσης συνεχίζεται για επιπλέον epochs.

```
checkpoint_cb = tf.keras.callbacks.ModelCheckpoint("alzheimer_model.h5",  
                                                save_best_only=True)
```

Η επανάκληση `EarlyStopping`` παρακολουθεί την απώλεια επικύρωσης και διακόπτει νωρίς την εκπαίδευση εάν η απόδοση του μοντέλου δεν βελτιωθεί, αποτρέποντας την υπερπροσαρμογή και τους περιττούς υπολογισμούς. Ο προγραμματιστής ρυθμού εκμάθησης ρυθμίζεται επίσης ως επανάκληση, επιτρέποντας δυναμικές προσαρμογές στον ρυθμό εκμάθησης σε κάθε epoch.

```
early_stopping_cb = tf.keras.callbacks.EarlyStopping(patience=10,  
                                                    restore_best_weights=True)
```

3.5.4. Εκπαίδευση

Το μοντέλο εκπαιδεύεται χρησιμοποιώντας τη μέθοδο `fit`` στο προετοιμασμένο σύνολο δεδομένων εκπαίδευσης ενώ επικυρώνεται στο σύνολο δεδομένων επικύρωσης. Αυτή η προσέγγιση παρέχει μια συνεχή αξιολόγηση της απόδοσης του μοντέλου σε αόρατα δεδομένα, μια κρίσιμη πτυχή για την αξιολόγηση της γενίκευσης του μοντέλου.

```
history = model.fit(train_dataset,  
                   validation_data=val_dataset,  
                   callbacks=[checkpoint_cb, early_stopping_cb, lr_scheduler],  
                   epochs=epochs)
```

Η εκπαίδευση διεξάγεται σε έναν προκαθορισμένο αριθμό εποχών, αλλά μπορεί να διακοπεί νωρίς με την επανάκληση `EarlyStopping`` εάν δεν υπάρξει βελτίωση στην απόδοση. Κατά τη διάρκεια κάθε epoch, το μοντέλο μαθαίνει

προσαρμόζοντας τα βάρη του για να ελαχιστοποιήσει τη συνάρτηση απώλειας, χρησιμοποιώντας το βελτιστοποιητή Adam. Η απώλεια εκπαίδευσης και επικύρωσης και η μέτρηση AUC παρακολουθούνται στενά καθ' όλη τη διάρκεια της εκπαιδευτικής διαδικασίας. Οι μετρήσεις απόδοσης οπτικοποιούνται μετά την εκπαίδευση, επιτρέποντας μια σαφή εικόνα της μαθησιακής προόδου του μοντέλου κατά τη διάρκεια των epochs. Αυτά τα διαγράμματα είναι σημαντικά για τη διάγνωση της εκπαιδευτικής διαδικασίας και τη λήψη τεκμηριωμένων αποφάσεων σχετικά με τις προσαρμογές του μοντέλου.

3.6.Επικύρωση

Κατά την διάρκεια της εκπαιδευτικής διαδικασίας, το μοντέλο περνάει από το στάδιο της επικύρωσης εξετάζοντας τα δεδομένα του αντίστοιχου σετ. Απώτερος σκοπός είναι η δοκιμή του μοντέλου στην ταξινόμηση δεδομένων με τα βάρη και bias που έχουν διαμορφωθεί κατά την διάρκεια της εκπαίδευσης. Έτσι, γίνεται η εξέταση του μοντέλου μέσω υπολογισμού μετρικών απόδοσης, όπως για παράδειγμα το ποσοστό απώλειας επικύρωσης, όπου στόχος είναι η μείωση της απώλειας και η τροποποίηση των βαρών στην επόμενη επανάκληση εκπαίδευσης για την παραγωγή καλύτερων επιδόσεων. Στο κεφάλαιο των αποτελεσμάτων γίνεται η συλλογή μετρικών απόδοσης της διαδικασίας εκπαίδευσης και επικύρωσης καθώς επίσης δημιουργούνται γραφήματα των μετρικών αυτών για οπτικοποίηση της εκπαιδευτικής πορείας του μοντέλου.

3.7.Αξιολόγηση Μοντέλου

Μετά την ολοκλήρωση της εκπαίδευσης, το μοντέλο υποβάλλεται σε μια φάση αξιολόγησης στο σύνολο δεδομένων δοκιμής. Αυτή η αξιολόγηση είναι κρίσιμη για την αξιολόγηση της απόδοσης του μοντέλου σε εντελώς άορατα δεδομένα, παρέχοντας πληροφορίες για το πόσο καλά γενικεύει το μοντέλο. Η αξιολόγηση καταλήγει σε μετρήσεις όπως η ακρίβεια (AUC), η επαναληψιμότητα (Precision), η ανάκληση (Recall) και η βαθμολογία F1 (F1 Score), προσφέροντας μια ολοκληρωμένη άποψη της αποτελεσματικότητας του μοντέλου στην ταξινόμηση των διαφορετικών σταδίων της AD. Η μήτρα σύγχυσης δημιουργείται επίσης και οπτικοποιείται, προσφέροντας μια λεπτομερή ματιά στην απόδοση ταξινόμησης του μοντέλου σε διαφορετικές κατηγορίες. Αυτή η οπτικοποίηση είναι ιδιαίτερα χρήσιμη για τον εντοπισμό τυχόν προκαταλήψεων ή αδυναμιών στο μοντέλο, όπως η συνεχής εσφαλμένη ταξινόμηση μιας συγκεκριμένης κατηγορίας.

3.7.1. Επαναληψιμότητα

Η επαναληψιμότητα στο πλαίσιο ενός μοντέλου ταξινόμησης είναι ένα μέτρο της ακρίβειας των θετικών προβλέψεων που γίνονται από το μοντέλο. Ασχολείται ιδιαίτερα με το ποσοστό των θετικών ταυτοποιήσεων που ήταν πραγματικά σωστές. Η επαναληψιμότητα είναι ιδιαίτερα σημαντική σε σενάρια όπου το κόστος ενός ψευδώς θετικού είναι υψηλό. Για παράδειγμα, στην ιατρική διαγνωστική, η ψευδής αναγνώριση ενός ασθενούς ως πάσχοντος από ασθένεια ενώ δεν έχει, θα μπορούσε να οδηγήσει σε περιττό άγχος, θεραπεία και έξοδα.

Μαθηματικά, η επαναληψιμότητα ορίζεται ως ο λόγος των αληθώς θετικών (TP) προς τον συνολικό αριθμό των θετικών προβλέψεων που γίνονται από το μοντέλο. Αυτό το σύνολο περιλαμβάνει τόσο τα αληθώς θετικά όσο και τα ψευδώς θετικά (FP), τα οποία είναι περιπτώσεις που εσφαλμένα προσδιορίζονται ως θετικές. Η εξίσωση για την επαναληψιμότητα είναι:

$$\text{Επαναληψιμότητα} = \frac{TP}{TP + FP}$$

Μια υψηλότερη επαναληψιμότητα υποδηλώνει χαμηλότερο ποσοστό ψευδώς θετικών. Ωστόσο, είναι σημαντικό να σημειωθεί ότι η επαναληψιμότητα από μόνη της δεν δίνει μια πλήρη εικόνα της απόδοσης ενός μοντέλου. Δεν λαμβάνει υπόψη τα ψευδώς αρνητικά (FN), τα οποία είναι οι περιπτώσεις που ταξινομήθηκαν λανθασμένα ως αρνητικές. Επομένως, η επαναληψιμότητα χρησιμοποιείται συχνά σε συνδυασμό με άλλες μετρήσεις όπως η ανάκληση (TPR), ή η ευαισθησία, η οποία μετρά την ικανότητα του μοντέλου να προσδιορίζει όλα τα πραγματικά θετικά.

3.7.2. Βαθμολογία F1

Η βαθμολογία F1 είναι ένα στατιστικό μέτρο που χρησιμοποιείται για την αξιολόγηση της απόδοσης των μοντέλων δυαδικής ταξινόμησης, ιδιαίτερα σε καταστάσεις όπου η ισορροπία μεταξύ επαναληψιμότητας και ανάκλησης είναι σημαντική. Είναι ιδιαίτερα χρήσιμο όταν αντιμετωπίζονται μη ισορροπημένα σύνολα δεδομένων ή όταν τόσο τα ψευδώς θετικά όσο και τα ψευδώς αρνητικά έχουν σημαντικό κόστος. Η βαθμολογία F1 ορίζεται ως η αρμονική μέση επαναληψιμότητα και ανάκληση. Ο αρμονικός μέσος όρος είναι ένας τύπος μέσου όρου, που χρησιμοποιείται ειδικά σε αυτό το πλαίσιο, επειδή δίνει μια πιο ισορροπημένη μέτρηση της απόδοσης ενός μοντέλου από την απλή επαναληψιμότητα και ανάκληση του μέσου όρου. Χρησιμοποιώντας τον αρμονικό μέσο όρο, η βαθμολογία F1 τιμωρεί τις ακραίες τιμές είτε επαναληψιμότητας είτε ανάκλησης. Αυτό σημαίνει ότι για να είναι υψηλό το σκορ της F1, ένα μοντέλο πρέπει να έχει τόσο υψηλή επαναληψιμότητα όσο και υψηλή ανάκληση. Ο τύπος για τη βαθμολογία F1 είναι:

$$\text{Βαθμολογία F1} = 2 \times \frac{\text{Επαναληψιμότητα} \times \text{Ανάκληση}}{\text{Επαναληψιμότητα} + \text{Ανάκληση}}$$

Σε αυτήν την εξίσωση, ο πολλαπλασιασμός με το 2 διασφαλίζει ότι εάν είτε η επαναληψιμότητα είτε η ανάκληση είναι μηδέν, η βαθμολογία F1 είναι επίσης μηδενική. Η βαθμολογία F1 κυμαίνεται από 0 έως 1, όπου το 1 υποδηλώνει τέλεια επαναληψιμότητα και ανάκληση και 0 σημαίνει ότι η επαναληψιμότητα ή η ανάκληση είναι μηδέν. [99] Είναι σημαντικό να σημειωθεί ότι η βαθμολογία F1 δεν είναι συμμετρική μεταξύ των κατηγοριών. Αυτή η ασυμμετρία σημαίνει ότι η τιμή της εξαρτάται από το ποια κατηγορία ορίζεται ως θετική και ποια ως αρνητική. Για παράδειγμα, σε ένα σύνολο δεδομένων όπου μια κλάση είναι σημαντικά μεγαλύτερη και ο ταξινομητής είναι προκατειλημμένος προς αυτήν την πλειοψηφική τάξη, η βαθμολογία F1 μπορεί να είναι παραπλανητικά υψηλή εάν αυτή η πλειοψηφική κλάση οριστεί ως η θετική κλάση. Αυτό συμβαίνει επειδή η βαθμολογία F1 είναι ανάλογη με τον αριθμό των αληθώς θετικών, που θα ήταν υψηλός σε ένα τέτοιο σενάριο. Αντίθετα, εάν οι ετικέτες επαναπροσδιοριστούν έτσι ώστε η αρνητική κλάση να γίνει η πλειοψηφία και ο ταξινομητής να παραμείνει προκατειλημμένος προς αυτήν την πλέον πλειοψηφική κλάση, η βαθμολογία F1 θα ήταν χαμηλή. Αυτή η κατάσταση δείχνει ότι, ενώ η βαθμολογία F1 είναι μια χρήσιμη μέτρηση, θα πρέπει να ερμηνεύεται προσεκτικά, ειδικά στο πλαίσιο των μη ισορροπημένων κλάσεων.

3.7.3. Καμπύλη ROC & Μέτρηση AUC

Μια καμπύλη ROC, ή καμπύλη χαρακτηριστικών λειτουργίας δέκτη, είναι μια γραφική αναπαράσταση που χρησιμοποιείται για την αξιολόγηση της απόδοσης ενός μοντέλου ταξινόμησης σε διάφορα κατώφλια. Είναι ιδιαίτερα αποτελεσματικό στην

οπτικοποίηση της αντιστάθμισης μεταξύ ευαισθησίας (Αληθώς Θετικό Ποσοστό: TPR) και ειδικότητας (1-Ψευδώς Θετικό Ποσοστό: 1-FPR).

Το Αληθώς Θετικό Ποσοστό (TPR), συνώνυμο με την ανάκληση, ορίζεται ως η αναλογία των σωστά προσδιορισμένων θετικών περιπτώσεων προς το σύνολο των πραγματικών θετικών περιπτώσεων. Αντανακλά την ικανότητα του μοντέλου να εντοπίζει σωστά τα θετικά αποτελέσματα και υπολογίζεται ως ο αριθμός των αληθινών θετικών (TP) διαιρεμένων με το άθροισμα των αληθινών θετικών (TP) και των ψευδών αρνητικών (FN).

$$TPR = \frac{TP}{TP + FN}$$


Ουσιαστικά, μετρά πόσο καλά το μοντέλο εντοπίζει θετικές περιπτώσεις.

Αντίθετα, το Ψευδώς Θετικό Ποσοστό (FPR) είναι η αναλογία των ψευδώς θετικών μεταξύ των συνολικών πραγματικών αρνητικών περιπτώσεων. Υπολογίζεται ως ο αριθμός των ψευδώς θετικών (FP) διαιρεμένος με το άθροισμα των ψευδώς θετικών (FP) και των αληθινών αρνητικών (TN).

$$FPR = \frac{FP}{FP + TN}$$

Το FPR ουσιαστικά μετρά την πιθανότητα το μοντέλο να ταξινομεί λανθασμένα ένα αρνητικό παράδειγμα ως θετικό. [97]

Σε μια καμπύλη ROC, το TPR απεικονίζεται στον άξονα y και το FPR στον άξονα x, για διάφορες ρυθμίσεις κατωφλίου. Τα κατώφλια σε ένα μοντέλο ταξινόμησης καθορίζουν το σημείο στο οποίο μια προβλεπόμενη πιθανότητα θεωρείται θετική έκβαση. Η μείωση αυτού του ορίου σημαίνει ότι περισσότερα στοιχεία ταξινομούνται ως θετικά, αυξάνοντας τόσο τα ψευδώς θετικά όσο και τα αληθώς θετικά. Αυτή η σχέση είναι που διαμορφώνει την καμπύλη ROC. Μια τυπική καμπύλη ROC ξεκινά από την κάτω αριστερή γωνία της γραφικής παράστασης (που αντιπροσωπεύει μια κατάσταση χωρίς ψευδώς θετικά και χωρίς αληθινά θετικά) και επεκτείνεται στην επάνω δεξιά γωνία (αντιπροσωπεύοντας μια κατάσταση με όλα τα θετικά που έχουν εντοπιστεί σωστά αλλά και όλα τα αρνητικά λανθασμένα). Η περιοχή κάτω από την καμπύλη (AUC) είναι μια κρίσιμη μέτρηση που προέρχεται από την καμπύλη ROC, παρέχοντας ένα μόνο μέτρο της συνολικής απόδοσης μιας δοκιμής. Μια AUC 1 υποδεικνύει μια τέλεια δοκιμή, όπου το μοντέλο ταξινομεί σωστά όλα τα θετικά και τα αρνητικά. Αντίθετα, μια AUC 0,5, που αντιπροσωπεύεται από τη διαγώνια γραμμή από (0,0) έως (1,1), υποδεικνύει ένα μοντέλο χωρίς διακριτική ισχύ, που ισοδυναμεί με τυχαία εικασία.



Εικόνα 3.4. Η περιοχή κάτω από την καμπύλη ROC (AUC), σκιαγραφημένη. [97]

Η ισχύς της καμπύλης ROC έγκειται στην ικανότητά της να εμφανίζει όλα τα πιθανά σημεία αποκοπής, επιτρέποντας την επιλογή ενός βέλτιστου ορίου με βάση την επιθυμητή ισορροπία μεταξύ ευαισθησίας και ειδικότητας. Αυτό το χαρακτηριστικό είναι ιδιαίτερα χρήσιμο καθώς η σημασία της ευαισθησίας έναντι της ειδικότητας μπορεί να ποικίλλει ανάλογα με το πλαίσιο ή την εφαρμογή του μοντέλου. Επιπλέον, η καμπύλη ROC παραμένει ανεπηρέαστη από τον επιπολασμό της νόσου στο σύνολο δεδομένων, καθώς βασίζεται σε ποσοστά και όχι σε απόλυτους αριθμούς. Αυτό το χαρακτηριστικό το καθιστά ένα ισχυρό εργαλείο, ειδικά σε ιατρικές διαγνωστικές εξετάσεις όπου ο επιπολασμός της νόσου μπορεί να ποικίλλει.

Εκτός από την παροχή μιας ολοκληρωμένης εικόνας της απόδοσης του μοντέλου σε όλα τα κατώφλια, η καμπύλη ROC επιτρέπει την οπτική σύγκριση πολλαπλών διαγνωστικών δοκιμών εντός της ίδιας γραφικής παράστασης. Αυτό το χαρακτηριστικό είναι ανεκτίμητο σε καταστάσεις όπου εξετάζονται πολλά μοντέλα ή δοκιμές και απαιτείται σαφής σύγκριση των επιδόσεών τους. Η καμπύλη ROC βοηθά επίσης στην εύρεση της απαραίτητης ισορροπίας μεταξύ ευαισθησίας και ειδικότητας. Ανάλογα με την εφαρμογή, μερικές φορές η υψηλή ευαισθησία είναι πιο κρίσιμη, ενώ σε άλλα σενάρια, η ειδικότητα μπορεί να είναι πιο σημαντική. Η καμπύλη ROC βοηθά στον εντοπισμό της σωστής διαμόρφωσης μοντέλου για την επίτευξη του επιθυμητού επιπέδου ευαισθησίας ή ειδικότητας. Ένα άλλο πλεονέκτημα της καμπύλης ROC είναι η αναλλοίωσή της στους μετασχηματισμούς. Η εμπειρική AUC παραμένει συνεπής ακόμη και όταν οι βαθμολογίες του ελέγχου μετασχηματίζονται, ας πούμε λαμβάνοντας έναν λογάριθμο ή μια τετραγωνική ρίζα. Αυτή η ιδιότητα διασφαλίζει ότι η καμπύλη ROC είναι ένα σταθερό μέτρο απόδοσης, ανεξάρτητα από την κλίμακα ή τον μετασχηματισμό που εφαρμόζεται στα δεδομένα. [98]

3.7.4. Απώλεια Hamming

Η απώλεια Hamming αποτελεί βασικό στοιχείο μέτρησης στο αντικείμενο της μηχανικής μάθησης, αποκτώντας ιδιαίτερη σημασία σε σενάρια ταξινόμησης πολλαπλών ετικετών. Αυτή η μέτρηση είναι καθοριστικής σημασίας για τη μέτρηση της αναλογίας εσφαλμένα προβλεπόμενων ετικετών σε σχέση με τον συνολικό αριθμό ετικετών, ποσοτικοποιώντας αποτελεσματικά τη συχνότητα εσφαλμένων προβλέψεων σε σύνολα ετικετών παραδειγμάτων. Είναι μια άμεση αντανάκλαση της ακρίβειας του μοντέλου στην πρόβλεψη ετικετών, υπογραμμίζοντας την ακρίβεια στον εντοπισμό των σωστών ετικετών για κάθε περίπτωση.

Η χρησιμότητα της απώλειας Hamming επεκτείνεται σημαντικά σε εργασίες ταξινόμησης πολλαπλών ετικετών, οι οποίες περιλαμβάνουν πολύπλοκα σενάρια όπως η πρόβλεψη πολλαπλών επιλοκών σε ασθενείς με έμφραγμα του μυοκαρδίου. Σε τέτοια πλαίσια, προσφέρει κρίσιμες γνώσεις σχετικά με την ικανότητα ενός μοντέλου να προβλέπει ταυτόχρονα πολλαπλές ετικέτες. Λειτουργεί ως μέτρο της ευρωστίας του μοντέλου και είναι ιδιαίτερα χρήσιμο κατά τη συγκριτική αξιολόγηση της απόδοσης σε διάφορους αλγόριθμους. Η απώλεια Hamming επαινείται για την ευθύτητα και τη σαφήνεια που προσφέρει στην αξιολόγηση του μοντέλου. Παρέχει μια διαισθητική κατανόηση, αντικατοπτρίζοντας το μέσο σφάλμα πρόβλεψης στο αναλυτικό επίπεδο κάθε παρουσίας και ετικέτας. Ωστόσο, δεν είναι χωρίς περιορισμούς. Σε σύνολα δεδομένων όπου η κατανομή ετικετών είναι ανισόρροπη και ορισμένες ετικέτες εμφανίζονται σπάνια, η απώλεια Hamming μπορεί να μην καταγράφει πλήρως τις περίπλοκες πτυχές της απόδοσης του μοντέλου. Αυτή η πτυχή υποδηλώνει την ανάγκη για προσεκτική ερμηνεία σε τέτοια σενάρια. [100]

Στη βαθιά μάθηση, ιδιαίτερα σε εφαρμογές όπως η ταξινόμηση εικόνων, η απώλεια Hamming αναλαμβάνει σημαντικό ρόλο. Συχνά χρησιμοποιείται παράλληλα με άλλες συναρτήσεις απώλειας για μια ολοκληρωμένη συγκριτική ανάλυση. Αυτή η αντιπαράθεση παρέχει μια διαφοροποιημένη προοπτική για την απόδοση του μοντέλου, δίνοντας ιδιαίτερη έμφαση στην ακρίβεια των προβλέψεων μεμονωμένων ετικετών, μια κρίσιμη πτυχή σε πολλές εφαρμογές βαθιάς μάθησης. [101]

3.7.5. Μήτρα Σύγκυσης

Ως μέρος της αξιολόγησης δημιουργείται ένας πίνακας που ονομάζεται μήτρα σύγκυσης. Είναι ιδιαίτερα χρήσιμη για τον εντοπισμό τυχόν δυναμικών στο μοντέλο, όπως η τάση για υπερβολική πρόβλεψη μιας συγκεκριμένης κατηγορίας. Κάθε γραμμή αυτού του πίνακα αντιστοιχεί στις περιπτώσεις μιας πραγματικής κλάσης, ενώ κάθε στήλη ευθυγραμμίζεται με τις περιπτώσεις σε μια προβλεπόμενη κλάση. Αυτή η διάταξη καθιστά τη μήτρα σύγκυσης χρήσιμη για την απεικόνιση της απόδοσης των αλγορίθμων στατιστικής ταξινόμησης. [102]

Στον πυρήνα της, η μήτρα αποτελείται από τέσσερα βασικά στοιχεία. Τα αληθώς θετικά (TP), αληθώς αρνητικά (TN), ψευδώς θετικά (FP) και ψευδώς αρνητικά (FN). Τα TP και TN υποδηλώνουν σωστά προσδιορισμένες ταξινομήσεις, με τα TP να είναι θετικές περιπτώσεις που προσδιορίζονται σωστά ως θετικές και τα TN να είναι αρνητικές περιπτώσεις που προσδιορίζονται σωστά ως αρνητικές. Αντίθετα, τα FP και τα FN αντιπροσωπεύουν τα σφάλματα στην ταξινόμηση, τα FP εμφανίζονται όταν οι αρνητικές περιπτώσεις ταξινομούνται λανθασμένα ως θετικές και τα FN εμφανίζονται όταν οι θετικές περιπτώσεις ταξινομούνται λανθασμένα ως αρνητικές.

		Actual Class	
		1	0
Predicted Class	1	True Positive	False Positive
	0	False Negative	True Negative


Εικόνα 3.5. Αναπαράσταση μήτρας σύγκυσης [103]

Η ευελιξία της μήτρας επεκτείνεται σε διάφορους τομείς εντός της βαθιάς μάθησης, που μπορεί να εφαρμοστεί τόσο σε προβλήματα ταξινόμησης δυαδικών όσο και πολλαπλών κλάσεων. Προσφέρει πληροφορίες όχι μόνο για την ακρίβεια ενός μοντέλου, αλλά φωτίζει επίσης τη φύση των σφαλμάτων που έγιναν, είτε το μοντέλο είναι επιρρεπές σε ψευδώς θετικά είτε ψευδώς αρνητικά. Αυτή η κατανόηση είναι ιδιαίτερης σημασίας για τη λεπτομερή ρύθμιση των παραμέτρων του μοντέλου και την επιλογή κατάλληλων μοντέλων με βάση συγκεκριμένες απαιτήσεις εφαρμογής.

3.7.6. Χαρτογράφηση Grad-CAM

Η χαρτογράφηση Grad-CAM (Gradient-weighted Class Activation Mapping) είναι μια καινοτόμος τεχνική στη σφαίρα της βαθιάς μάθησης. Προσφέρει οπτικές εξηγήσεις για τις αποφάσεις που λαμβάνονται από τα CNN. Το Grad-CAM λειτουργεί χρησιμοποιώντας τις κλίσεις οποιασδήποτε έννοιας στόχου, που διοχετεύονται στο τελικό συνελκτικό στρώμα του CNN. Αυτή η διαδικασία δημιουργεί έναν χάρτη εντοπισμού που τονίζει οπτικά τις κεντρικές περιοχές σε μια εικόνα που είναι υπεύθυνη για την πρόβλεψη της έννοιας. [104]

Στον τομέα της ιατρικής απεικόνισης, η εφαρμογή του Grad-CAM έχει δείξει αξιοσημείωτη αποτελεσματικότητα. Ένα παράδειγμα άξιο αναφοράς είναι η χρήση του στην ανάλυση εικόνων ακτινογραφίας θώρακα για την ανίχνευση του COVID-19. Εδώ, το Grad-CAM διαδραματίζει κρίσιμο ρόλο κατευθύνοντας την εστίαση των CNN στις βασικές περιοχές ενδεικτικές μόλυνσης. Αυτή η προσέγγιση όχι μόνο ενισχύει την ποιοτική αξιολόγηση, αλλά προσθέτει και μια ποσοτική διάσταση στις διαδικασίες διάγνωσης και ταξινόμησης.



Εικόνα 3.6. Grad-CAM εφαρμοσμένο σε ακτινογραφίες θώρακος [105]

Το Grad-CAM συμβάλλει σημαντικά στο πεδίο της μηχανικής όρασης αυξάνοντας την επεξήγηση των μοντέλων CNN. Αυτό το κάνει οπτικοποιώντας τις περιοχές μέσα στις εικόνες που τα μοντέλα θεωρούν κρίσιμες για την κρίση ταξινόμησης. Αυτό το χαρακτηριστικό είναι ιδιαίτερα ωφέλιμο σε σύνθετες αναλύσεις εικόνας. Η ευελιξία του επεκτείνεται στη συνδυαστική χρήση του με άλλες τεχνικές βαθιάς μάθησης. Σε εργασίες όπως η ανίχνευση αντικειμένων, το Grad-CAM έχει ενσωματωθεί αποτελεσματικά με προηγμένα μοντέλα όπως το Mask R-CNN [106]. Αυτή η ενοποίηση όχι μόνο ενισχύει την ακρίβεια ανίχνευσης, αλλά παρέχει επίσης βαθύτερες γνώσεις σχετικά με τις εστιακές περιοχές του μοντέλου. [106]

3.8. Περιορισμοί και προκλήσεις

Στο πλαίσιο της χρήσης μοντέλων βαθιάς μάθησης για την ταξινόμηση των σταδίων της AD από εικόνες MRI, όπως παρατηρήθηκε σε αυτή τη μελέτη, αντιμετωπίστηκαν αρκετοί περιορισμοί και προκλήσεις. Αυτά αφορούν τόσο το σύνολο δεδομένων όσο και το μοντέλο, επηρεάζοντας τα αποτελέσματα και τις ερμηνείες της μελέτης.

Η απόδοση του μοντέλου και η γενίκευσή του συνδέονται εγγενώς με τα χαρακτηριστικά και την ποιότητα του συνόλου δεδομένων. Ένας αξιοσημείωτος περιορισμός στο σύνολο δεδομένων περιλαμβάνει την ανισορροπία κλάσης. Η διαφορά στον αριθμό των εικόνων στα διάφορα στάδια της AD, ιδιαίτερα η υποεκπροσώπηση ορισμένων κατηγοριών, όπως το ModerateDemented, αποτελεί σημαντική πρόκληση. Αυτή η ανισορροπία μπορεί να οδηγήσει σε ένα δυναμικό του μοντέλου προς πιο αντιπροσωπευόμενες τάξεις, επηρεάζοντας την ακρίβεια και την ευθύτητα των προβλέψεων του μοντέλου. Ένας άλλος περιορισμός σχετίζεται με τη φύση των ίδιων των εικόνων MRI. Το σύνολο δεδομένων αποτελείται από

προεπεξεργασμένες εικόνες μαγνητικής τομογραφίας, πράγμα που σημαίνει ότι ορισμένα χαρακτηριστικά ή ανωμαλίες ενδέχεται να έχουν τροποποιηθεί ή αφαιρεθεί κατά την προεπεξεργασία. Αυτό θα μπορούσε ενδεχομένως να οδηγήσει σε απώλεια κρίσιμων πληροφοριών που θα μπορούσαν να είναι ιδιαίτερης σημασίας για την ακριβή ταξινόμηση της νόσου.

Όσον αφορά το μοντέλο, ενώ η βαθιά μάθηση προσφέρει ισχυρές δυνατότητες εξαγωγής χαρακτηριστικών, η φύση του «μαύρου κουτιού» θέτει έναν περιορισμό όσον αφορά την ερμηνευτικότητα. Η κατανόηση του συλλογισμού πίσω από συγκεκριμένες ταξινομήσεις ή εσφαλμένες ταξινομήσεις από το μοντέλο είναι πρόκληση, κάτι που μπορεί να είναι ένα σημαντικό μειονέκτημα σε κλινικά περιβάλλοντα όπου η επεξήγηση είναι βαρυσήμαντη. Επιπλέον, η υπολογιστική πολυπλοκότητα και οι απαιτήσεις πόρων για την εκπαίδευση μοντέλων βαθιάς μάθησης δεν πρέπει να αγνοηθούν. Η ανάγκη για GPU υψηλής τεχνολογίας για αποτελεσματική εκπαίδευση θα μπορούσε να περιορίσει την προσβασιμότητα και την επεκτασιμότητα της ανάπτυξης τέτοιων μοντέλων σε ποικίλα κλινικά περιβάλλοντα.

Αναφορικά στη μελέτη, αντιμετωπίστηκαν διάφορες προκλήσεις, που σχετίζονται κυρίως με το χειρισμό δεδομένων και τη βελτιστοποίηση μοντέλων. Η πρώτη πρόκληση ήταν η διασφάλιση της ποιότητας και της συνέπειας της προεπεξεργασίας δεδομένων. Δεδομένων των ποικίλων πηγών του συνόλου δεδομένων, η διατήρηση της ομοιομορφίας στο μέγεθος, την ανάλυση και τη μορφή της εικόνας απαιτούσε σχολαστική προεπεξεργασία, η οποία ήταν χρονοβόρα και πολύπλοκη. Μια άλλη πρόκληση ήταν ο συντονισμός των υπερπαραμέτρων για το μοντέλο βαθιάς μάθησης. Η εύρεση του βέλτιστου συνόλου παραμέτρων, όπως ο ρυθμός εκμάθησης, ο αριθμός των επιπέδων και οι νευρώνες σε κάθε επίπεδο, απαιτούσε εκτεταμένο πειραματισμό και επικύρωση. Αυτή η διαδικασία ήταν επαναληπτική και υπολογιστικά εντατική. Τέλος, η επικύρωση και η ερμηνεία της απόδοσης του μοντέλου ήταν μια πρόκληση. Η διασφάλιση ότι οι μετρήσεις υψηλής απόδοσης του μοντέλου ήταν πραγματικά ενδεικτικές της προγνωστικής του ισχύος και όχι ως αποτέλεσμα υπερπροσαρμογής ή δυναμικών προς μια συγκεκριμένη κατηγορία απαιτούσε αυστηρές μεθόδους επικύρωσης και ολοκληρωμένη κατανόηση των υποκείμενων δεδομένων. Ενώ το μοντέλο έδειξε πολλά υποσχόμενο στην ταξινόμηση σταδίων της AD από εικόνες MRI, οι περιορισμοί και οι προκλήσεις της μελέτης υπογραμμίζουν την ανάγκη για συνεχή έρευνα και βελτίωση.

Έχοντας περιγράψει διεξοδικά τις περιπλοκές της μεθοδολογίας, συμπεριλαμβάνοντας τις λεπτομερείς διαδικασίες προετοιμασίας δεδομένων, σχεδιασμό αρχιτεκτονικής μοντέλων, εκπαίδευση, επικύρωση, καθώς και τα κρίσιμα στοιχεία υλικού και λογισμικού που στήριξαν τη μελέτη, γίνεται μετάβαση στο κεντρικό κεφάλαιο των αποτελεσμάτων. Το επερχόμενο κεφάλαιο είναι έτοιμο να αποκαλύψει τις πρακτικές επιπτώσεις της εφαρμογής του μοντέλου βαθιάς μάθησης στην ταξινόμηση σταδίων της AD. Στόχος του είναι να παρουσιάσει μια σαφή και περιεκτική ανάλυση της απόδοσης του μοντέλου, ενοποιώντας αυτά τα ευρήματα στο πλαίσιο των περιορισμών και των προκλήσεων που συζητήθηκαν προηγουμένως. Αυτό το κεφάλαιο όχι μόνο θα παρουσιάσει την αποτελεσματικότητα και την ακρίβεια του μοντέλου, αλλά θα εμβαθύνει επίσης στις διαφοροποιημένες ερμηνείες των αποτελεσμάτων, προσφέροντας μια κριτική αξιολόγηση της δυνατότητας εφαρμογής του μοντέλου στον πραγματικό κόσμο και του πιθανού αντίκτυπου στον τομέα της ιατρικής έρευνας.

4. Αποτελέσματα Μελέτης

Στο κεφάλαιο των αποτελεσμάτων αυτής της μελέτης, εστιάζεται η παρουσίαση τους και των τιμών που παράγονται από το μοντέλο βαθιάς μάθησης. Αυτό το κεφάλαιο είναι δομημένο για να εμφανίζει μεθοδικά τα αποτελέσματα που λαμβάνονται για κάθε συνάρτηση ενεργοποίησης που χρησιμοποιείται στο μοντέλο, (ReLU, Leaky ReLU, PReLU, ELU), σε ξεχωριστές υποενότητες. Κάθε υποενότητα θα παρέχει τα ποσοτικά αποτελέσματα της απόδοσης του μοντέλου με την αντίστοιχη λειτουργία ενεργοποίησης, προσφέροντας μια σαφή και συνοπτική παρουσίαση των δεδομένων.

Ο στόχος εδώ είναι να παράσχει μια απλή και τεκμηριωμένη αναπαράσταση των αποτελεσμάτων, με σύντομες εξηγήσεις που συνοδεύουν κάθε σύνολο αποτελεσμάτων για να βοηθήσουν στην ερμηνεία τους. Η εστίαση είναι στην παροχή μιας ξεκάθαρης και απερίττης άποψης του τρόπου με τον οποίο το μοντέλο απέδωσε σε διαφορετικές διαμορφώσεις, επιτρέποντας στα δεδομένα να μιλήσουν από μόνα τους. Αυτή η προσέγγιση διασφαλίζει μια διαφανή και αντικειμενική παρουσίαση των δυνατοτήτων του μοντέλου, όπως προκύπτει άμεσα από τις εξόδους του κώδικα.

4.1. Αποτελέσματα με συνάρτηση ενεργοποίησης ReLU

▪ Αρχείο καταγραφής διαδικασίας εκπαίδευσης, επικύρωσης και ελέγχου του μοντέλου

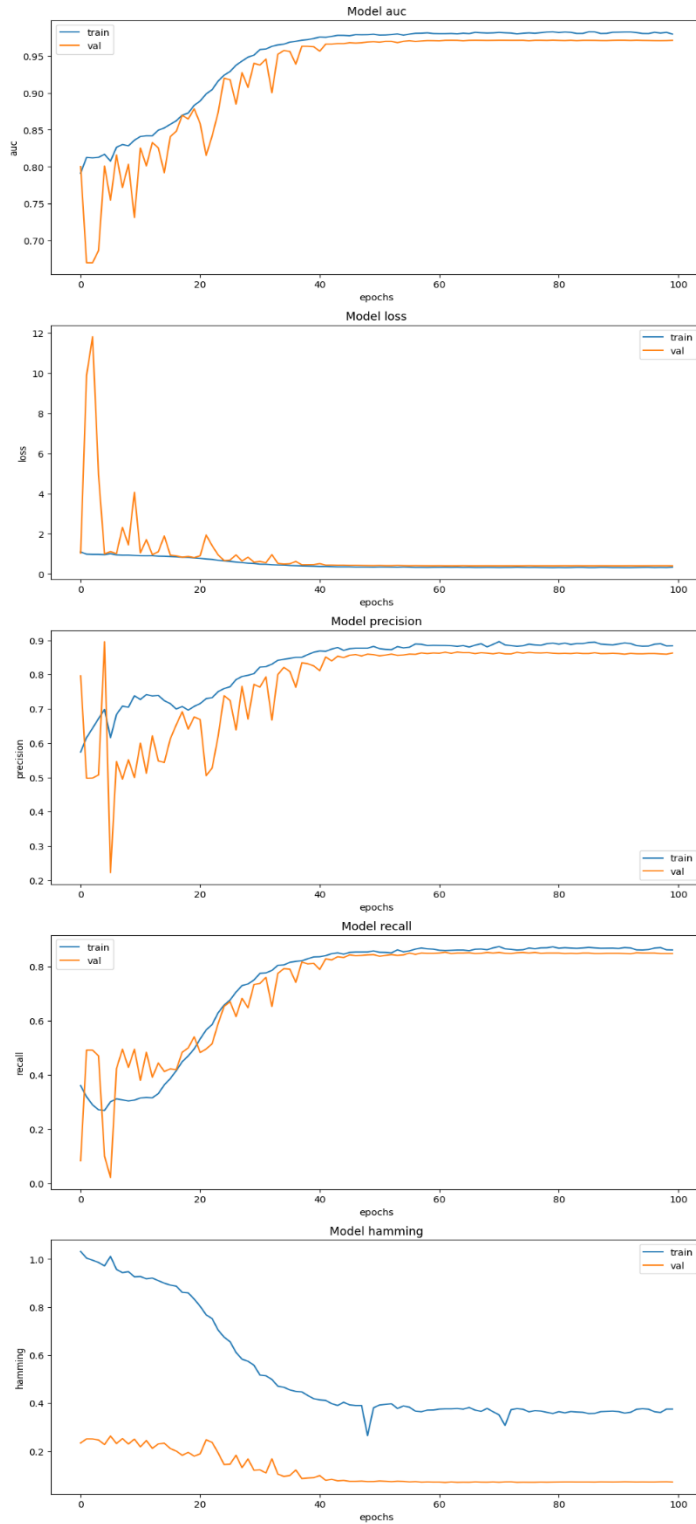
Η διαδικασία εκπαίδευσης του μοντέλου περιλαμβάνει πολλαπλά epochs, κατά τα οποία καταγράφονται σχολαστικά μια σειρά από μετρήσεις, συμπεριλαμβανομένων των απωλειών, της ακρίβειας, της επαναληψιμότητας, της ανάκλησης, της AUC και της απώλειας hamming. Συγκεκριμένα, η ακρίβεια του μοντέλου ξεκινά περίπου στο 50,87% στο πρώτο epoch, η επαναληψιμότητα στο 57,39%, η ανάκληση στο 36,10 %, η AUC στο 79,13%, και η απώλεια hamming στο 103,17%. Όλες οι μετρήσεις εμφανίζουν βελτίωση στα επόμενα epochs και οι τελικές τιμές των μετρήσεων στο τέλος της εκπαίδευσης είναι στο 33,09% για την απώλεια, 87,50% ακρίβεια, 88,41% επαναληψιμότητα, 86,21% ανάκληση, 97,94% AUC και 37,55% απώλεια hamming. Σύμφωνα με τις συγκεκριμένες μετρήσεις λοιπόν, διαμορφώνονται ανάλογα και οι μετρήσεις κατά τη διάρκεια της επικύρωσης.

Μετά την τελική αξιολόγηση στο σύνολο δεδομένων δοκιμής, το μοντέλο πέτυχε ακρίβεια 60,67%, επαναληψιμότητα 61,22%, ανάκληση 60,36% και AUC 85,12%, με απώλεια hamming που καταγράφηκε στο 24.36%.

Πίνακας 4.1. Τελικές τιμές μετρήσεων του μοντέλου με συνάρτηση ενεργοποίησης ReLU από το αρχείο καταγραφής


ReLU	Απώλεια	Ακρίβεια	Επαναληψιμότητα	Ανάκληση	AUC	Απώλεια Hamming
Εκπαίδευση	0.3309	0.8750	0.8841	0.8621	0.9794	0.3755
Επικύρωση	0.3997	0.8574	0.8630	0.8486	0.9710	0.0715
Αξιολόγηση	1.2660	0.6067	0.6122	0.6035	0.8511	0.2435

ΔΙΑΓΝΩΣΗ ΤΗΣ ΝΟΣΟΥ ΤΟΥ ΑΛΤΣΧΑΙΜΕΡ ΜΕ ΧΡΗΣΗ ΒΑΘΙΑΣ ΜΑΘΗΣΗΣ ΚΑΙ
ΑΝΑΛΥΣΗΣ ΕΙΚΟΝΑΣ



Εικόνα 4.1. Γραφήματα μετρήσεων απώλειας, ακρίβειας, επαναληψιμότητας, ανάκλησης, AUC και απώλειας hamming κατά τη διάρκεια εκπαίδευσης (μπλε γραμμή) και επικύρωσης (πορτοκαλί γραμμή) για το μοντέλο με συνάρτηση ενεργοποίησης ReLU

ΔΙΑΓΝΩΣΗ ΤΗΣ ΝΟΣΟΥ ΤΟΥ ΑΛΤΣΧΑΙΜΕΡ ΜΕ ΧΡΗΣΗ ΒΑΘΙΑΣ ΜΑΘΗΣΗΣ ΚΑΙ ΑΝΑΛΥΣΗΣ ΕΙΚΟΝΑΣ

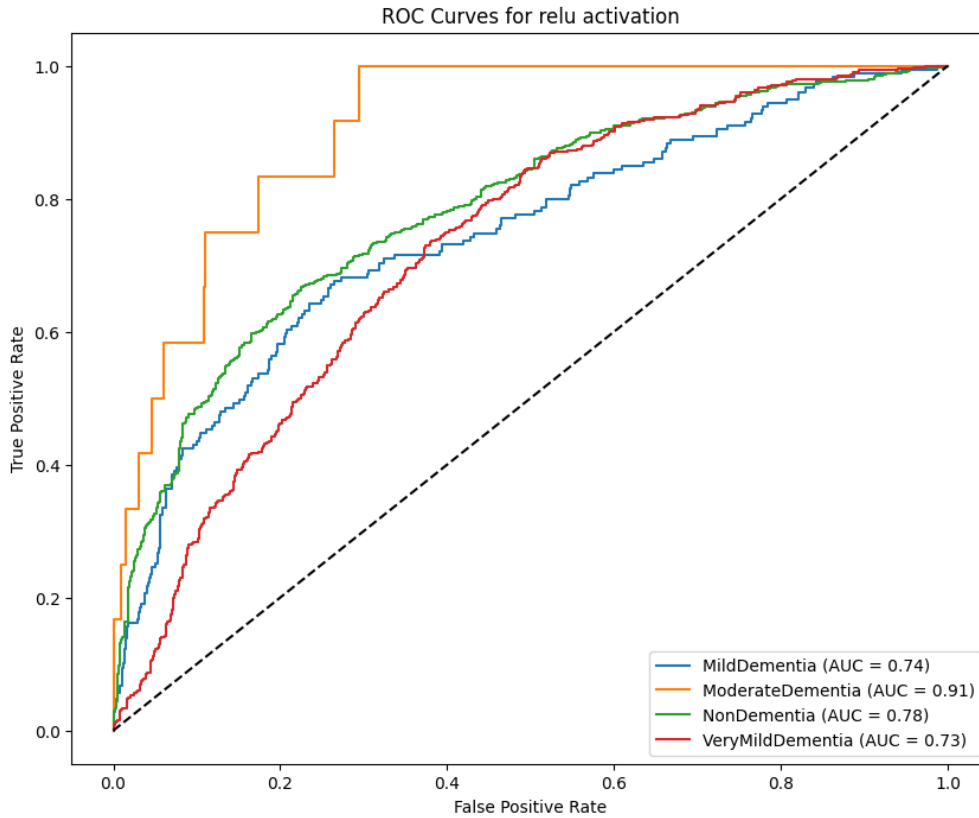


Εικόνα 4.2. Μήτρα Σύγκρισης των δεδομένων εικόνων κάθε σταδίου της νόσου Alzheimer και των προβλεπόμενων εικόνων του μοντέλου με συνάρτηση ενεργοποίησης ReLU.

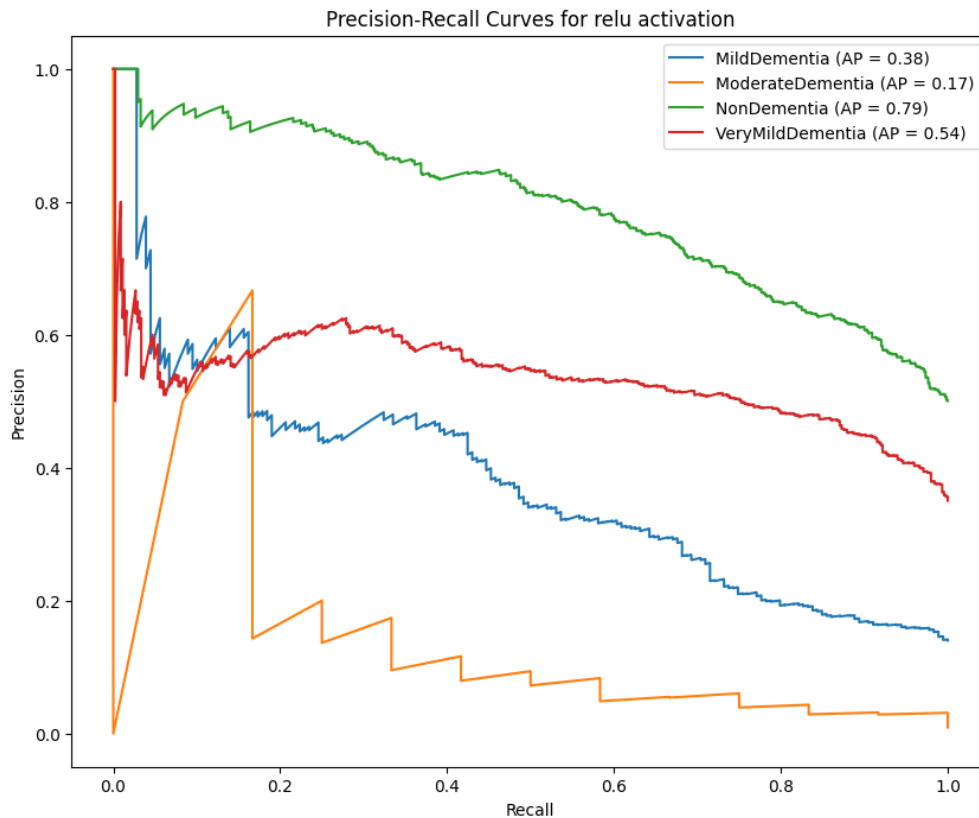
Πίνακας 4.2. Τιμές μετρήσεων με συνάρτηση ενεργοποίησης ReLU σε κάθε στάδιο της νόσου Alzheimer

Κατηγορία	Αριθμός εικόνων	Επαναληψιμότητα	Ανάκληση	Βαθμολογία F1
MildDementia	179	0.48	0.16	0.24
ModerateDementia	12	0.00	0.00	0.00
NonDementia	640	0.72	0.69	0.70
VeryMildDementia	448	0.51	0.69	0.58
Μακρομέσος Όρος	1279	0.43	0.38	0.38
Σταθμισμένος Μέσος Όρος	1279	0.60	0.61	0.59


ΔΙΑΓΝΩΣΗ ΤΗΣ ΝΟΣΟΥ ΤΟΥ ΑΛΤΣΧΑΙΜΕΡ ΜΕ ΧΡΗΣΗ ΒΑΘΙΑΣ ΜΑΘΗΣΗΣ ΚΑΙ ΑΝΑΛΥΣΗΣ ΕΙΚΟΝΑΣ



Εικόνα 4.3. Καμπύλη ROC συνάρτησης ενεργοποίησης ReLU για κάθε κλάση της νόσου Alzheimer



Εικόνα 4.4. Καμπύλη Επαναληψιμότητας – Ανάκλησης συνάρτησης ενεργοποίησης ReLU για κάθε κλάση της νόσου Alzheimer



Εικόνα 4.5. Grad-CAM οπτικοποίηση μοντέλου με συνάρτηση ενεργοποίησης ReLU σε εικόνες MRI εγκεφάλων από το σετ δεδομένων εκπαίδευσης

4.2.Αποτελέσματα με συνάρτηση ενεργοποίησης Leaky ReLU


- Αρχείο καταγραφής διαδικασίας εκπαίδευσης, επικύρωσης και ελέγχου του μοντέλου

Το μοντέλο που χρησιμοποιεί τη συνάρτηση ενεργοποίησης Leaky ReLU υποβλήθηκε σε εκπαίδευση για συνολικά 68 epochs. Κατά τη διάρκεια αυτής της περιόδου, υπήρξε μια αξιοσημείωτη και σταθερή βελτίωση στις διάφορες μετρήσεις απόδοσης. Αυτή η εξέλιξη καταδεικνύει την ικανότητα του μοντέλου να μαθαίνει και να προσαρμόζεται με την πάροδο του χρόνου, βελτιώνοντας την ακρίβεια και την αξιοπιστία του στις εργασίες ταξινόμησης. Στο τελικό epoch της εκπαίδευσής του, το μοντέλο Leaky ReLU έδειξε εντυπωσιακά αποτελέσματα στο σύνολο επικύρωσης, επιτυγχάνοντας ακρίβεια 98,97%, επαναληψιμότητα 99,00%, ανάκληση 98,95%, AUC 99,96% και απώλεια Hamming 2,00%.

Μετά την αξιολόγηση στο δοκιμαστικό σετ, το μοντέλο με ενεργοποίηση Leaky ReLU πέτυχε ακρίβεια 69,66%, επαναληψιμότητα 70,06%, ανάκληση 69,51%, AUC, το υψηλότερο μέχρι στιγμής ποσοστό, στα 87,08% και απώλεια Hamming 18,83%


Πίνακας 4.3. Τελικές τιμές μετρήσεων του μοντέλου με συνάρτηση ενεργοποίησης *Leaky ReLU* από το αρχείο καταγραφής

<i>Leaky ReLU</i>	Απώλεια	Ακρίβεια	Επαναληψιμότητα	Ανάκληση	AUC	Απώλεια Hamming
Εκπαίδευση	0.0342	0.9897	0.9900	0.9895	0.9996	0.1450
Επικύρωση	0.1539	0.9600	0.9600	0.9600	0.9908	0.0200
Αξιολόγηση	1.5723	0.6966	0.7006	0.6951	0.8708	0.1883



Εικόνα 4.6. Γραφήματα μετρήσεων απώλειας, ακρίβειας, επαναληψιμότητας, ανάκλησης, AUC και απώλειας hamming κατά τη διάρκεια εκπαίδευσης (μπλε γραμμή) και επικύρωσης (πορτοκαλί γραμμή) για το μοντέλο με συνάρτηση ενεργοποίησης *Leaky ReLU*

ΔΙΑΓΝΩΣΗ ΤΗΣ ΝΟΣΟΥ ΤΟΥ ΑΛΤΣΧΑΙΜΕΡ ΜΕ ΧΡΗΣΗ ΒΑΘΙΑΣ ΜΑΘΗΣΗΣ ΚΑΙ ΑΝΑΛΥΣΗΣ ΕΙΚΟΝΑΣ




Εικόνα 4.7. Μήτρα Σύγχυσης των δεδομένων εικόνων κάθε σταδίου της νόσου Alzheimer και των προβλεπόμενων εικόνων του μοντέλου με συνάρτηση ενεργοποίησης Leaky ReLU.

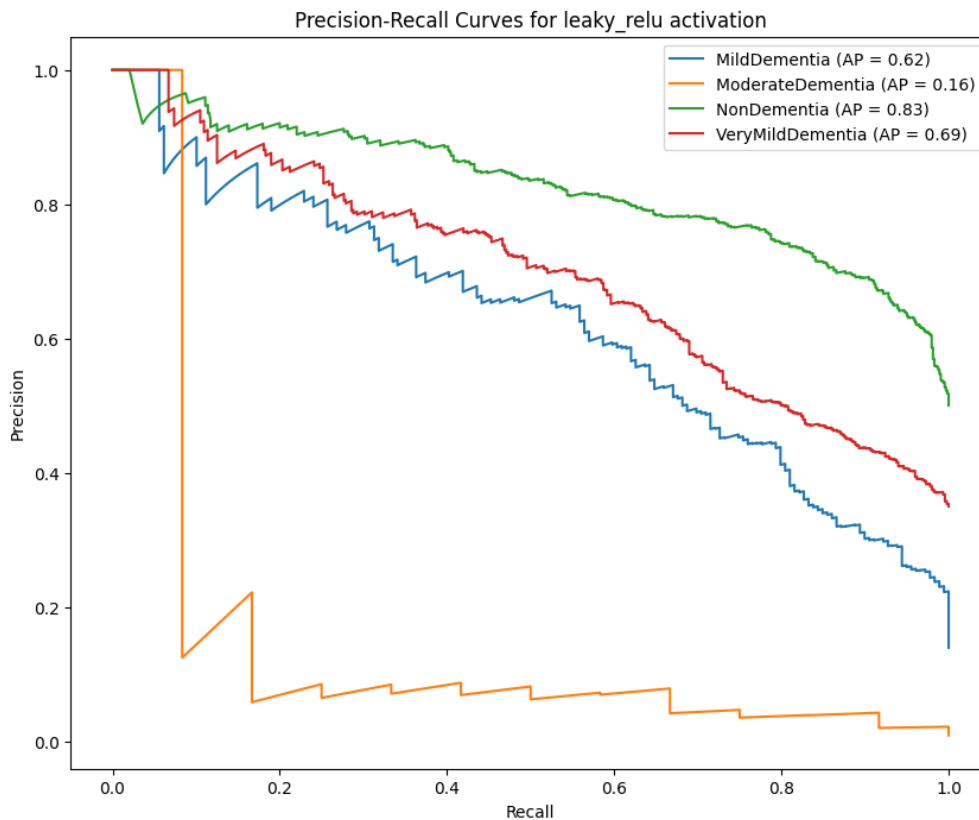
Πίνακας 4.4. Τιμές μετρήσεων με συνάρτηση ενεργοποίησης Leaky ReLU σε κάθε στάδιο της νόσου Alzheimer

Κατηγορία	Αριθμός εικόνων	Επαναληψιμότητα	Ανάκληση	Βαθμολογία F1
MildDementia	179	0.65	0.55	0.60
ModerateDementia	12	0.25	0.08	0.12
NonDementia	640	0.71	0.85	0.78
VeryMildDementia	448	0.69	0.54	0.61
Μακρομέσος Όρος	1279	0.57	0.51	0.53
Σταθμισμένος Μέσος Όρος	1279	0.69	0.70	0.69


ΔΙΑΓΝΩΣΗ ΤΗΣ ΝΟΣΟΥ ΤΟΥ ΑΛΤΣΧΑΙΜΕΡ ΜΕ ΧΡΗΣΗ ΒΑΘΙΑΣ ΜΑΘΗΣΗΣ ΚΑΙ ΑΝΑΛΥΣΗΣ ΕΙΚΟΝΑΣ



Εικόνα 4.8. Καμπύλη ROC συνάρτησης ενεργοποίησης Leaky ReLU για κάθε κλάση της νόσου Alzheimer



Εικόνα 4.9. Καμπύλη Επαναληψιμότητας – Ανάκλησης συνάρτησης ενεργοποίησης Leaky ReLU για κάθε κλάση της νόσου Alzheimer



Εικόνα 4.10. Grad-CAM οπτικοποίηση μοντέλου με συνάρτηση ενεργοποίησης Leaky ReLU σε εικόνες MRI εγκεφάλων από το σετ δεδομένων εκπαίδευσης

4.3.Αποτελέσματα με συνάρτηση ενεργοποίησης PReLU


- Αρχείο καταγραφής διαδικασίας εκπαίδευσης, επικύρωσης και ελέγχου του μοντέλου

Κατά τη διάρκεια 35 epochs, το μοντέλο που χρησιμοποιούσε τη συνάρτηση ενεργοποίησης PReLU εμφάνισε κυμαινόμενες τιμές απώλειας και ακρίβειας. Τέτοιες παραλλαγές δεν είναι ασυνήθιστες στις εφαρμογές της βαθιάς μάθησης, ιδιαίτερα κατά τις αρχικές φάσεις της εκπαίδευσης όπου το μοντέλο εξακολουθεί να προσαρμόζεται και να μαθαίνει από τα δεδομένα. Στο τελευταίο epoch επικύρωσης, το μοντέλο πέτυχε αξιοσημείωτα αποτελέσματα με ακρίβεια 96,09%, επαναληψιμότητα 96,09%, ανάκληση 96,00%, AUC 98,63% και απώλεια Hamming 1,98%.

Ωστόσο, όταν εφαρμόστηκε στο σετ ελέγχου, υπήρξε αξιοσημείωτη μείωση στην απόδοση. Το μοντέλο κατέγραψε ακρίβεια 56,29%, επαναληψιμότητα 56,15%, ανάκληση 55,67%, AUC 78,25% και απώλεια Hamming 27,45%.


Πίνακας 4.5. Τελικές τιμές μετρήσεων του μοντέλου με συνάρτηση ενεργοποίησης PReLU από το αρχείο καταγραφής

PReLU	Απώλεια	Ακρίβεια	Επαναληψιμότητα	Ανάκληση	AUC	Απώλεια Hamming
Εκπαίδευση	0.0153	0.9963	0.9963	0.9963	1.0000	0.0073
Επικύρωση	0.2380	0.9609	0.9609	0.9600	0.9863	0.0198
Αξιολόγηση	2.4041	0.5629	0.5615	0.5567	0.7825	0.2745



Εικόνα 4.11. Γραφήματα μετρήσεων απώλειας, ακρίβειας, επαναληψιμότητας, ανάκλησης, AUC και απώλειας hamming κατά τη διάρκεια εκπαίδευσης (μπλε γραμμή) και επικύρωσης (πορτοκαλί γραμμή) για το μοντέλο με συνάρτηση ενεργοποίησης PReLU

ΔΙΑΓΝΩΣΗ ΤΗΣ ΝΟΣΟΥ ΤΟΥ ΑΛΤΣΧΑΙΜΕΡ ΜΕ ΧΡΗΣΗ ΒΑΘΙΑΣ ΜΑΘΗΣΗΣ ΚΑΙ ΑΝΑΛΥΣΗΣ ΕΙΚΟΝΑΣ




Εικόνα 4.12. Μήτρα Σύγκρισης των δεδομένων εικόνων κάθε σταδίου της νόσου Alzheimer και των προβλεπόμενων εικόνων του μοντέλου με συνάρτηση ενεργοποίησης PReLU.


Πίνακας 4.6. Τιμές μετρήσεων με συνάρτηση ενεργοποίησης PReLU σε κάθε στάδιο της νόσου Alzheimer

Κατηγορία	Αριθμός εικόνων	Επαναληψιμότητα	Ανάκληση	Βαθμολογία F1
MildDementia	179	0.65	0.18	0.29
ModerateDementia	12	0.00	0.00	0.00
NonDementia	640	0.67	0.67	0.67
VeryMildDementia	448	0.44	0.58	0.50
Μακρομέσος Όρος	1279	0.44	0.36	0.36
Σταθμισμένος Μέσος Όρος	1279	0.58	0.56	0.55


ΔΙΑΓΝΩΣΗ ΤΗΣ ΝΟΣΟΥ ΤΟΥ ΑΛΤΣΧΑΙΜΕΡ ΜΕ ΧΡΗΣΗ ΒΑΘΙΑΣ ΜΑΘΗΣΗΣ ΚΑΙ
ΑΝΑΛΥΣΗΣ ΕΙΚΟΝΑΣ



Εικόνα 4.13. Καμπύλη ROC συνάρτησης ενεργοποίησης PReLU για κάθε κλάση της νόσου Alzheimer



Εικόνα 4.14. Καμπύλη Επαναληψιμότητας – Ανάκλησης συνάρτησης ενεργοποίησης PReLU για κάθε κλάση της νόσου Alzheimer



Εικόνα 4.15. Grad-CAM οπτικοποίηση μοντέλου με συνάρτηση ενεργοποίησης PReLU σε εικόνες MRI εγκεφάλων από το σετ δεδομένων εκπαίδευσης

4.4.Αποτελέσματα με συνάρτηση ενεργοποίησης ELU

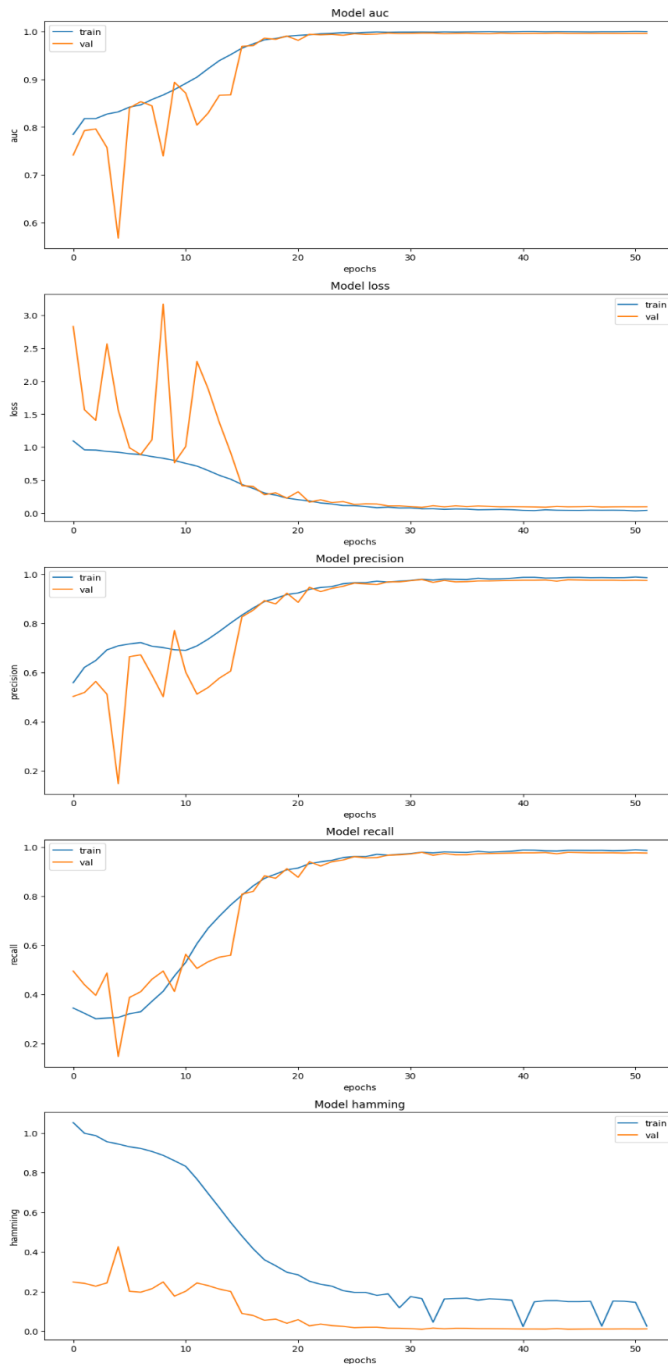
- Αρχείο καταγραφής διαδικασίας εκπαίδευσης, επικύρωσης και ελέγχου του μοντέλου

Η έκδοση του μοντέλου με συνάρτηση ενεργοποίησης ELU υποβλήθηκε σε μια εκτεταμένη φάση εκπαίδευσης που καλύπτει 52 epochs, όπου κατά τη διάρκεια της εκπαίδευσης, παρατηρούμε διακυμάνσεις στις μετρήσεις της απόδοσης του μοντέλου με φυσιολογικό ρυθμό εξέλιξης λόγω της σταδιακής προσαρμογής των αποχρώσεων των δεδομένων εκπαίδευσης και επικύρωσης. Σύμφωνα με το αρχείο καταγραφής, στο τελικό epoch της εκπαίδευσης του μοντέλου, οι μετρήσεις απόδοσης είχαν βελτιωθεί σημαντικά με την ακρίβεια να είναι στο 98,66%, επαναληψιμότητα 98,68%, ανάκληση 98,63%, AUC 99,95% και απώλεια Hamming 2,69%.

Αντίθετα, η απόδοση του μοντέλου στο σετ ελέγχου αποκάλυψε σημαντική πτώση. Η ακρίβεια μετρήθηκε στο 64,74%, με επαναληψιμότητα 64,86%, ανάκληση 64,66%, AUC 84,70% και απώλεια Hamming 22,03%.


Πίνακας 4.7. Τελικές τιμές μετρήσεων του μοντέλου με συνάρτηση ενεργοποίησης ELU από το αρχείο καταγραφής

ELU	Απώλεια	Ακρίβεια	Επαναληψιμότητα	Ανάκληση	AUC	Απώλεια Hamming
Εκπαίδευση	0.0421	0.9866	0.9868	0.9863	0.9995	0.0269
Επικύρωση	0.0975	0.9756	0.9756	0.9756	0.9959	0.0122
Αξιολόγηση	1.6890	0.6476	0.6486	0.6466	0.8470	0.2203



Εικόνα 4.16. Γραφήματα μετρήσεων απώλειας, ακρίβειας, επαναληψιμότητας, ανάκλησης, AUC και απώλειας hamming κατά τη διάρκεια εκπαίδευσης (μπλε γραμμή) και επικύρωσης (πορτοκαλί γραμμή) για το μοντέλο με συνάρτηση ενεργοποίησης ELU

ΔΙΑΓΝΩΣΗ ΤΗΣ ΝΟΣΟΥ ΤΟΥ ΑΛΤΣΧΑΙΜΕΡ ΜΕ ΧΡΗΣΗ ΒΑΘΙΑΣ ΜΑΘΗΣΗΣ ΚΑΙ ΑΝΑΛΥΣΗΣ ΕΙΚΟΝΑΣ




Εικόνα 4.17. Μήτρα Σύγχυσης των δεδομένων εικόνων κάθε σταδίου της νόσου Alzheimer και των προβλεπόμενων εικόνων του μοντέλου με συνάρτηση ενεργοποίησης ELU.


Πίνακας 4.8. Τιμές μετρήσεων με συνάρτηση ενεργοποίησης ELU σε κάθε στάδιο της νόσου Alzheimer

Κατηγορία	Αριθμός εικόνων	Επαναληψιμότητα	Ανάκληση	Βαθμολογία F1
MildDementia	179	0.71	0.27	0.40
ModerateDementia	12	1.00	0.17	0.29
NonDementia	640	0.71	0.78	0.74
VeryMildDementia	448	0.55	0.63	0.59
Μακρομέσος Όρος	1279	0.74	0.46	0.50
Σταθμισμένος Μέσος Όρος	1279	0.66	0.65	0.63


ΔΙΑΓΝΩΣΗ ΤΗΣ ΝΟΣΟΥ ΤΟΥ ΑΛΤΣΧΑΙΜΕΡ ΜΕ ΧΡΗΣΗ ΒΑΘΙΑΣ ΜΑΘΗΣΗΣ ΚΑΙ ΑΝΑΛΥΣΗΣ ΕΙΚΟΝΑΣ



Εικόνα 4.18. Καμπύλη ROC συνάρτησης ενεργοποίησης ELU για κάθε κλάση της νόσου Alzheimer

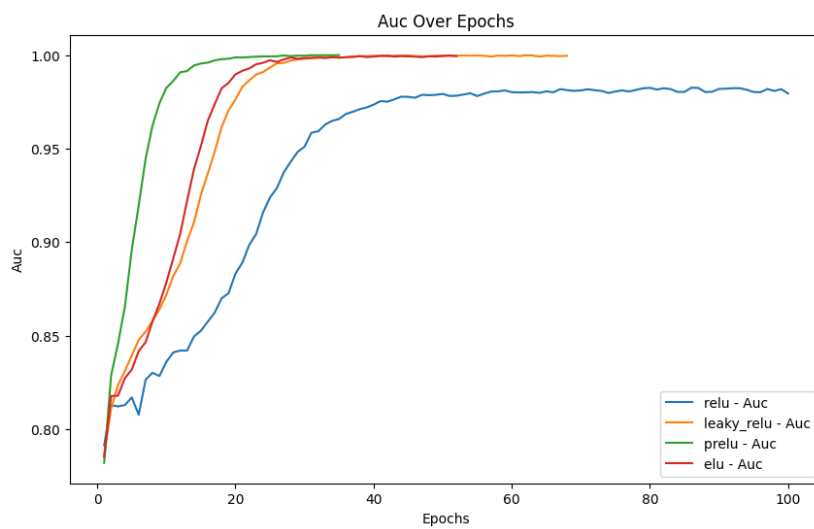


Εικόνα 4.19. Καμπύλη Επαναληψιμότητας – Ανάκλησης συνάρτησης ενεργοποίησης ELU για κάθε κλάση της νόσου Alzheimer



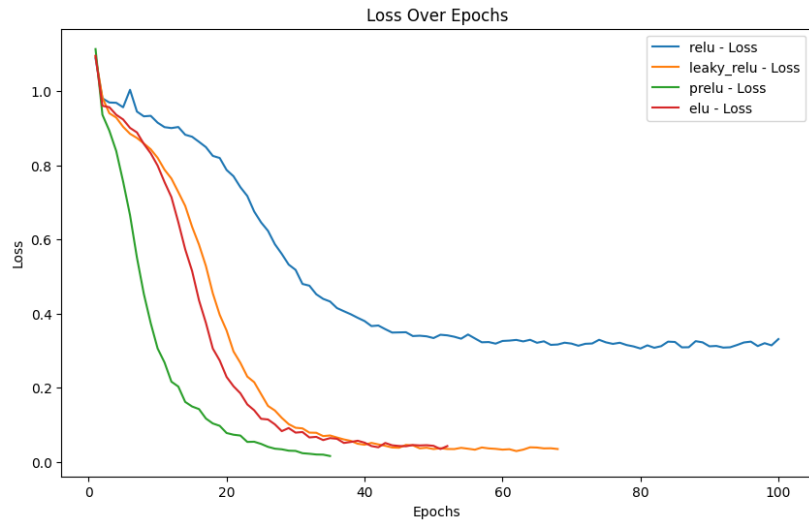
Εικόνα 4.20. Grad-CAM οπτικοποίηση μοντέλου με συνάρτηση ενεργοποίησης ELU σε εικόνες MRI εγκεφάλων από το σετ δεδομένων εκπαίδευσης

4.5. Γραφήματα συγκρίσεων απόδοσης μεταξύ συναρτήσεων ενεργοποίησης

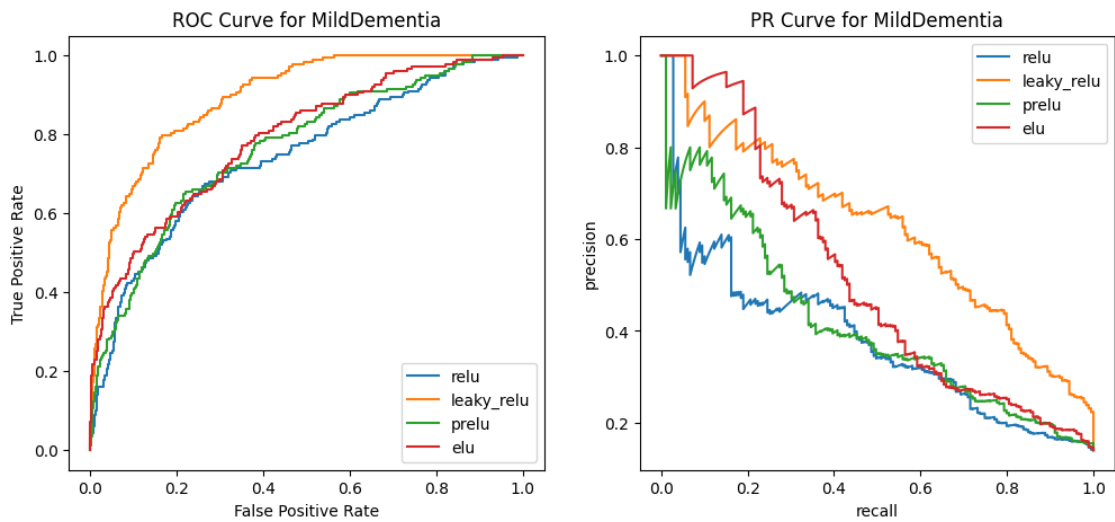


Εικόνα 4.21. Γράφημα σύγκρισης AUC μεταξύ συναρτήσεων ενεργοποίησης σε epochs

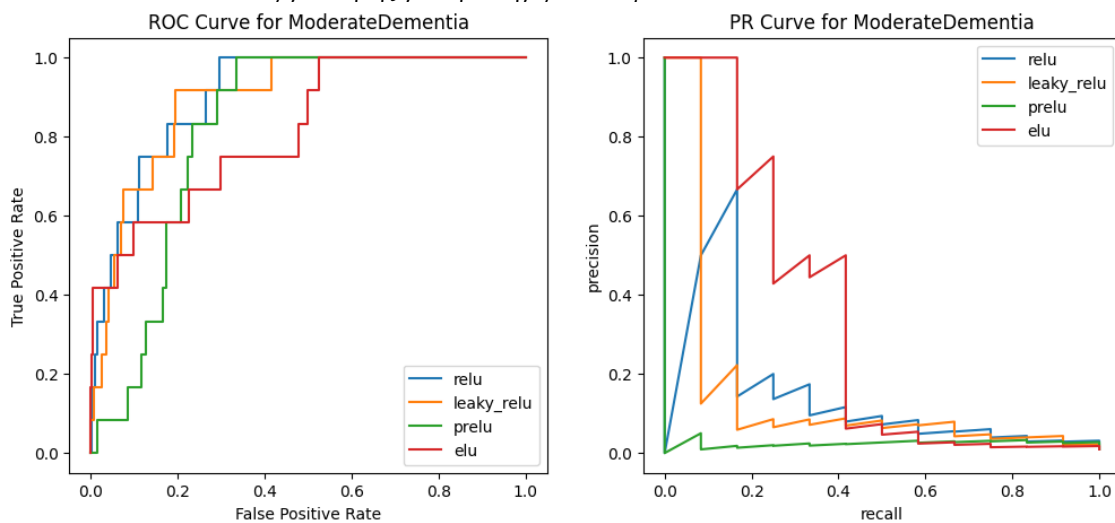
ΔΙΑΓΝΩΣΗ ΤΗΣ ΝΟΣΟΥ ΤΟΥ ΑΛΤΣΧΑΙΜΕΡ ΜΕ ΧΡΗΣΗ ΒΑΘΙΑΣ ΜΑΘΗΣΗΣ ΚΑΙ ΑΝΑΛΥΣΗΣ ΕΙΚΟΝΑΣ



Εικόνα 4.22. Γράφημα σύγκρισης απώλειας μεταξύ συναρτήσεων ενεργοποίησης σε epochs




Εικόνα 4.23. 1^ο Γράφημα: Καμπύλες ROC των συναρτήσεων ενεργοποίησης για τη κατηγορία δεδομένων MildDementia (ήπια άνοια), 2^ο Γράφημα: Καμπύλες επαναληψιμότητας – ανάκλησης των συναρτήσεων ενεργοποίησης για τη κατηγορία δεδομένων MildDementia




Εικόνα 4.24. 1^ο Γράφημα: Καμπύλες ROC των συναρτήσεων ενεργοποίησης για τη κατηγορία δεδομένων ModerateDementia (μέτρια άνοια), 2^ο Γράφημα: Καμπύλες επαναληψιμότητας – ανάκλησης των συναρτήσεων ενεργοποίησης για τη κατηγορία δεδομένων ModerateDementia

ΔΙΑΓΝΩΣΗ ΤΗΣ ΝΟΣΟΥ ΤΟΥ ΑΛΤΣΧΑΙΜΕΡ ΜΕ ΧΡΗΣΗ ΒΑΘΙΑΣ ΜΑΘΗΣΗΣ ΚΑΙ
ΑΝΑΛΥΣΗΣ ΕΙΚΟΝΑΣ



Εικόνα 4.25. 1^ο Γράφημα: Καμπύλες ROC των συναρτήσεων ενεργοποίησης για τη κατηγορία δεδομένων NonDementia (χωρίς άνοια), 2^ο Γράφημα: Καμπύλες επαναληψιμότητας – ανάκλησης των συναρτήσεων ενεργοποίησης για τη κατηγορία δεδομένων NonDementia



Εικόνα 4.26. 1^ο Γράφημα: Καμπύλες ROC των συναρτήσεων ενεργοποίησης για τη κατηγορία δεδομένων VeryMildDementia (πολύ ήπια άνοια), 2^ο Γράφημα: Καμπύλες επαναληψιμότητας – ανάκλησης των συναρτήσεων ενεργοποίησης για τη κατηγορία δεδομένων VeryMildDementia

5. Συζήτηση & Συμπεράσματα

Αυτή η διπλωματική εργασία αποτελεί βασικό παράδειγμα ενσωμάτωσης τεχνικών DL στην ιατρική διάγνωση, ιδιαίτερα στην ανίχνευση και ταξινόμηση των συμπτωμάτων της AD σε εικόνες MRI εγκεφάλου. Το κύριο επίτευγμα αυτής της εργασίας είναι η ανάπτυξη ενός κώδικα βασισμένου στο TensorFlow, μοναδικά προσαρμοσμένου ώστε να αναλύει και να ταξινομεί αυτές τις εικόνες. Αυτή η εξέλιξη σηματοδοτεί ένα σημαντικό βήμα στη χρησιμοποίηση προηγμένων υπολογιστικών μεθόδων για ιατρική απεικόνιση. Ενώ οι πρωταρχικοί στόχοι επιτεύχθηκαν, το έργο αντιμετώπισε αξιοσημείωτες προκλήσεις, ιδίως όσον αφορά τους περιορισμούς δεδομένων και την υπερπροσαρμογή, γεγονός που εμπόδισε σημαντικά την απόδοση του κώδικα κατά την εκπαίδευση και την αξιολόγηση. Για να αντιμετωπιστούν αυτά τα ζητήματα, πραγματοποιήθηκαν τροποποιήσεις στην αρχιτεκτονική του κώδικα και στις τεχνικές που χρησιμοποιήθηκαν. Αυτές οι προσαρμογές περιελάμβαναν την εξερεύνηση διαφόρων συναρτήσεων ενεργοποίησης και τη βελτίωση των επιπέδων νευρωνικών δικτύων, με στόχο να ενισχυθεί η ικανότητα του μοντέλου να γενικεύει και να μαθαίνει αποτελεσματικά από τα διαθέσιμα δεδομένα. Η αποτελεσματικότητα αυτών των τροποποιήσεων παρακολούθηθηκε στενά μέσω προηγμένων τεχνικών οπτικοποίησης μοντέλων και συναρτήσεων μετρικής καταγραφής. Αυτά τα εργαλεία συνέβαλαν καθοριστικά στη μετάφραση σύνθετων δεδομένων απόδοσης σε πρακτικές πληροφορίες, καθοδηγώντας περαιτέρω βελτιώσεις. Βασικές μετρήσεις όπως η ακρίβεια, η απώλεια, η επαναληψιμότητα και η ανάκληση αναλύθηκαν σχολαστικά για να αξιολογηθούν οι διαγνωστικές δυνατότητες του μοντέλου.

Σε αυτό το κεφάλαιο, πραγματοποιήθηκε εμβάθυνση σε μια αξιολόγηση των αποτελεσμάτων που προκύπτουν από τον κώδικα. Ξεκινώντας, γίνεται ανάλυση του αντίκτυπου κάθε συνάρτησης ενεργοποίησης που εφαρμόζεται, ακολουθούμενη από μια συγκριτική αξιολόγηση των μετρήσεων απόδοσης. Αυτή η ανάλυση όχι μόνο υπογραμμίζει τις επιτυχίες αλλά ρίχνει φως και στους τομείς όπου το μοντέλο εξακολουθεί να απαιτεί βελτίωση. Οι περιορισμοί που συναντήθηκαν, ιδιαίτερα το εύρος και η ισορροπία του συνόλου δεδομένων, είχαν σημαντική επίδραση στην απόδοση του μοντέλου. Οι μελλοντικές επαναλήψεις αυτού του έργου θα μπορούσαν να επικεντρωθούν στην επέκταση του συνόλου δεδομένων, ειδικά σε υποεκπροσωπούμενα στάδια της AD, και στη χρήση στρατηγικών όπως η αύξηση δεδομένων για να ξεπεραστούν αυτές οι προκλήσεις.

5.1. Σχολιασμός αποτελεσμάτων συνάρτησης ReLU

ReLU: Αρχείο καταγραφής

- Κατά την αξιολόγηση του αποτελέσματος της εκπαιδευτικής διαδικασίας, επισημαίνονται διάφορες βασικές μετρήσεις (βλ Πίνακα 4.1.) για να υπολογιστεί η αποτελεσματικότητα του μοντέλου. Το AUC, ένας κρίσιμος δείκτης της ικανότητας του μοντέλου στη διαφοροποίηση της τάξης, εμφανίζει σταθερότητα σε όλες τα epochs (βλ. Εικ. 4.1.), υποδηλώνοντας μια ισχυρή ικανότητα διάκρισης μεταξύ των κλάσεων. Ωστόσο, η διαφορά που παρατηρείται μεταξύ του AUC εκπαίδευσης και επικύρωσης υποδηλώνει πιθανή υπερπροσαρμογή, όπως αποδεικνύεται από την ανώτερη απόδοση των δεδομένων εκπαίδευσης σε σχέση με τα μη εμφανή δεδομένα επικύρωσης. Οι τάσεις της απώλειας μοντέλου αποκαλύπτουν μια αρχική απότομη πτώση που ακολουθείται από αυξομειώσεις, μια χαρακτηριστική τροχιά στην εκπαίδευση βαθιάς μάθησης. Αξιοσημείωτες είναι οι σποραδικές αιχμές στην απώλεια επικύρωσης, υπονοώντας πιθανές προκλήσεις στην εκμάθηση του μοντέλου ή θορυβώδεις παρεμβολές δεδομένων

επικύρωσης. Η δυναμική της ακρίβειας και της ανάκλησης εμφανίζει αρχική αστάθεια, σταθεροποιούμενη με την πάροδο του χρόνου, ωστόσο η σταθερή υποαπόδοσή τους στην επικύρωση σε σχέση με την εκπαίδευση υπογραμμίζει την ανησυχία της υπερπροσαρμογής. Ειδικότερα, η πτωτική τάση της απώλειας Hamming στα δεδομένα εκπαίδευσης αντανακλά θετικά στην καμπύλη εκμάθησης του μοντέλου, σε αντίθεση με μια ελαφρά αύξηση στην απώλεια Hamming της επικύρωσης, υποδηλώνοντας πιθανώς την υπερπροσαρμογή ή την πολυπλοκότητα του συνόλου επικύρωσης. Στο σετ ελέγχου, ενώ το AUC πάνω από 85% υποδηλώνει επαρκή ικανότητα πρόβλεψης κατηγορίας, το ποσοστό ακρίβειας 60,67% και η απώλεια Hamming 24,36% υπογραμμίζουν σημαντικά περιθώρια βελτίωσης, ειδικά για εφαρμογές που απαιτούν υψηλή ακρίβεια.

ReLU: Μήτρα Σύγχυσης

- Η ανάλυση μήτρας σύγχυσης για το μοντέλο ταξινόμησης με την ενεργοποίηση ReLU (βλ. *Εικ. 4.2.*) που καλύπτει τέσσερα στάδια άνοιας, αποκαλύπτει ποικίλες επιδόσεις μεταξύ των τάξεων. Το μοντέλο παλεύει περισσότερο με την Ήπια Άνοια (MildDementia), εντοπίζοντας σωστά μόνο 29 περιπτώσεις και ταξινομώντας εσφαλμένα σημαντικούς αριθμούς ως Πολύ Ήπια Άνοια (VeryMildDementia) και Χωρίς Άνοια (NonDementia), υποδεικνύοντας δυσκολία στη διάκριση αυτών των καταστάσεων. Η μέτρια άνοια (ModerateDementia), με πολύ χαμηλό μέγεθος δείγματος, δεν βλέπει σωστές προβλέψεις, υποδεικνύοντας την αναξιοπιστία σε αυτήν την κατηγορία. Το NonDementia είναι ένα δυνατό σημείο για το μοντέλο, με μεγάλο αριθμό αληθώς θετικών, αν και με αξιοσημείωτες εσφαλμένες ταξινομήσεις από το VeryMildDementia. Το μοντέλο αποδίδει αρκετά καλά στον εντοπισμό της VeryMildDementia, αλλά η σύγχυση με το NonDementia υποδηλώνει περιθώρια βελτίωσης. Η ανάλυση υποδεικνύει μια πιθανή προκατάληψη προς την κατηγορία NonDementia, πιθανώς λόγω ανισορροπίας κλάσης στο σύνολο δεδομένων εκπαίδευσης.

ReLU: Πίνακας μετρήσεων απόδοσης κατά κατηγορία

- Η ανάλυση της απόδοσης κατά κατηγορία χρησιμοποιώντας τη συνάρτηση ενεργοποίησης ReLU (βλ. *Πίνακας 4.2.*) αποκαλύπτει σημαντικές διαφορές μεταξύ των τάξεων. Η MildDementia είναι ιδιαίτερα προκλητική για το μοντέλο, όπως αποδεικνύεται από χαμηλή επαναληψιμότητα (0,48) και ακόμη χαμηλότερη ανάκληση (0,16), που οδηγεί σε κακή βαθμολογία F1 (0,24). Αυτό υποδηλώνει δυσκολία στην ακριβή πρόβλεψη και αναγνώριση περιπτώσεων σε αυτήν την κατηγορία. Η ModerateDementia είναι η πιο προβληματική, με το μοντέλο να μην μπορεί να προσδιορίσει σωστά καμία περίπτωση, αντανακλώντας είτε ανεπαρκή αναπαράσταση δεδομένων είτε αδυναμία διάκρισης χαρακτηριστικών κλάσης. Η NonDementia, ωστόσο, ξεχωρίζει με την υψηλότερη επαναληψιμότητα (0,72) και ανάκληση (0,69), επιδεικνύοντας την ικανότητα του μοντέλου σε αυτήν την κατηγορία. Η VeryMildDementia παρουσιάζει μέτρια επαναληψιμότητα (0,51) αλλά καλύτερη ανάκληση (0,69), υποδηλώνοντας κάποια ικανότητα αλλά και σύγχυση με τη NonDementia. Αυτά τα ευρήματα υπογραμμίζουν μια έντονη προκατάληψη του μοντέλου προς τη NonDementia, πιθανώς λόγω ανισορροπίας τάξης.

ReLU: Καμπύλες ROC & Επαναληψιμότητας – Ανάκλησης

- Οι καμπύλες ROC και οι βαθμολογίες AUC για το μοντέλο ταξινόμησης που χρησιμοποιεί τη λειτουργία ενεργοποίησης ReLU (βλ. *Εικ. 4.3.*) παρέχουν μια ολοκληρωμένη αξιολόγηση της ικανότητάς του να διακρίνει τα διάφορα στάδια άνοιας. Το μοντέλο δείχνει μέτρια δυνατότητα διαχωρισμού για την MildDementia (AUC = 0,74) και την VeryMildDementia (AUC = 0,73),

υποδεικνύοντας μια λογική ικανότητα διαφοροποίησης αυτών των κατηγοριών από άλλες. Παραδόξως, η ModerateDementia (AUC = 0,91) δείχνει υψηλό βαθμό διαχωρισμού παρά την περιορισμένη επιτυχία του μοντέλου στην επαναληψιμότητα και την ανάκληση για αυτήν την κατηγορία, υποδηλώνοντας ότι η βαθμολογία AUC μπορεί να είναι υπερβολικά αισιόδοξη λόγω του μικρού αριθμού θετικών παραδειγμάτων. Η NonDementia επιτυγχάνει AUC 0,78, υπογραμμίζοντας την ικανότητα του μοντέλου στον εντοπισμό αυτής της κατάστασης. Οι καμπύλες PR (βλ. *Εικ. 4.4.*) αποκαλύπτουν ποικίλους βαθμούς ισορροπίας μεταξύ των κατηγοριών, με τη NonDementia να παρουσιάζει την ισχυρότερη απόδοση (AP = 0,79) και την ModerateDementia την πιο αδύναμη (AP = 0,17). Αυτά τα ευρήματα υποδηλώνουν ότι ενώ το μοντέλο είναι γενικά αποτελεσματικό στη διάκριση της NonDementia, παλεύει με την πιο εναλλαγμένη διαφοροποίηση που απαιτείται για τη ModerateDementia, πιθανώς λόγω περιορισμένης ή μη ισορροπημένης αναπαράστασης δεδομένων.

ReLU: Οπτικοποίηση Grad-CAM

- Οι οπτικοποιήσεις Grad-CAM που χρησιμοποιούν την ενεργοποίηση ReLU (βλ. *Εικ. 4.5.*) φωτίζουν τη διαδικασία λήψης αποφάσεων του μοντέλου επισημαίνοντας περιοχές σημαντικής ενεργοποίησης στις κεντρικές περιοχές του εγκεφάλου. Κυρίως, οι ενεργοποιήσεις συγκεντρώνονται σε βασικές δομές όπως οι βρεγματικοί λοβοί, νησιωτικό φλοιό, οι μετωπιαίοι λοβοί και η κυκλική έλικα [107], με τα θερμότερα χρώματα να επισημαίνουν αυτές τις περιοχές ως κρίσιμες για τις προβλέψεις του μοντέλου. Ωστόσο, ορισμένες εικόνες εμφανίζουν ελάχιστη ενεργοποίηση, περιορισμένη σε μικρές περιοχές, εγείροντας ερωτήματα σχετικά με τη συνέπεια του μοντέλου στην ιεράρχηση των σχετικών χαρακτηριστικών για τη διάγνωση. Αυτή η μεταβλητότητα υποδηλώνει ένα πιθανό κενό στη μάθηση του μοντέλου, είτε λόγω των παρουσιαζόμενων περιπτώσεων που δεν εκδηλώνουν ευδιάκριτα τα μαθησιακά χαρακτηριστικά είτε λόγω της αδυναμίας του μοντέλου να εστιάσει ομοιόμορφα σε σχετικές δομές του εγκεφάλου σε διαφορετικές περιπτώσεις.

Συμπέρασμα απόδοσης μοντέλου με συνάρτηση ενεργοποίησης ReLU

- Το μοντέλο εμφανίζει σημάδια υπερπροσαρμογής, όπως αποδεικνύεται από την ασυμφωνία μεταξύ των μετρήσεων απόδοσης εκπαίδευσης και επικύρωσης, ιδιαίτερα στα γραφήματα AUC και απώλειας. Αυτό το ζήτημα επιδεινώνεται από την ανισορροπία κλάσης, που επηρεάζει σημαντικά την ικανότητα του μοντέλου να ταξινομεί με ακρίβεια την MildDementia και τη ModerateDementia, με αυτές τις κατηγορίες να εμφανίζουν χαμηλότερες τιμές επαναληψιμότητας και ανάκλησης. Αν και το μοντέλο επιδεικνύει υψηλή AUC για ModerateDementia, αυτό έρχεται σε αντίθεση με την κακή επαναληψιμότητα και ανάκληση, υπογραμμίζοντας μια πιθανή υπερβολική εμπιστοσύνη σε περιορισμένες σωστές προβλέψεις και αμφισβητώντας την αξιοπιστία των μετρήσεων απόδοσης για αυτήν την κατηγορία. Η ισχυρότερη απόδοση του μοντέλου παρατηρείται στην κατηγορία NonDementia, υποδηλώνοντας μια πιθανή προκατάληψη λόγω της υψηλότερης εκπροσώπησής του στο σετ εκπαίδευσης. Η αντιστάθμιση επαναληψιμότητας – ανάκλησης και οι οπτικοποιήσεις Grad-CAM υπογραμμίζουν περαιτέρω τις προκλήσεις του μοντέλου στη σταθερή εστίαση σε σχετικά χαρακτηριστικά. Με μια σχετικά υψηλή απώλεια Hamming που υποδεικνύει σημαντικό ποσοστό σφάλματος, το μοντέλο, ενώ παρουσιάζει δυνατότητες, απαιτεί ουσιαστική βελτίωση και ένα πιο ισορροπημένο σύνολο δεδομένων για αξιόπιστες ιατρικές διαγνωστικές εφαρμογές.

5.2.Σχολιασμός αποτελεσμάτων συνάρτησης Leaky ReLU

Leaky ReLU: Αρχείο καταγραφής (log)

- Η ευθυγράμμιση μεταξύ των AUC εκπαίδευσης και επικύρωσης (βλ. *Εικ. 4.6.*) υποδηλώνει αποτελεσματική γενίκευση και μετριασμό των ανησυχιών περί υπερπροσαρμογής. Παρά τις διακυμάνσεις της απώλειας επικύρωσης, η φθίνουσα τάση τόσο στην εκπαίδευση όσο και στην απώλεια επικύρωσης σημαίνει επιτυχημένη ελαχιστοποίηση σφαλμάτων. Η μέτρηση επαναληψιμότητας, ενδεικτική της ακρίβειας πρόβλεψης θετικής κλάσης του μοντέλου, και η ανάκληση, αντανακλώντας την ικανότητά του να εντοπίζει όλες τις σχετικές περιπτώσεις, καταδεικνύει αρχικές ανισότητες που μειώνονται με την πάροδο του χρόνου, υπογραμμίζοντας τη βελτίωση της γενίκευσης. Η απώλεια Hamming μειώνεται στην εκπαίδευση, υποδεικνύοντας την αποτελεσματικότητα εκμάθησης, αν και μια ελαφρά αύξηση στην απώλεια Hamming επικύρωσης μπορεί να υποδηλώνει μικρή υπερπροσαρμογή ή ποικίλη πολυπλοκότητα του δείγματος επικύρωσης. Οι αξιολογήσεις σετ ελέγχου (βλ. *Πίνακας 4.3.*) αποκαλύπτουν σχεδόν 70% ακρίβεια, επαναληψιμότητα και ανάκληση, μαζί με μια βαθμολογία AUC που υπερβαίνει το 0,87, επιβεβαιώνοντας την ισχυρή διακριτική δύναμη και συνέπεια του μοντέλου. Μια απώλεια hamming 18% στο σετ ελέγχου, μια βελτίωση από τις εκπαιδεύσεις, σημαίνει αποτελεσματική απόδοση αόρατων δεδομένων. Συνολικά, το μοντέλο παρουσιάζει αξιόπαινες δυνατότητες γενίκευσης και σταθερή απόδοση σετ ελέγχου.

Leaky ReLU: Μήτρα Σύγχυσης

- Η MildDementia αναγνωρίζεται με κάποια ακρίβεια, αλλά η σύγχυση με την VeryMildDementia και τη NonDementia υπογραμμίζει τις προκλήσεις στην οριοθέτηση (βλ. *Εικ. 4.7.*). Η ModerateDementia αποδεικνύεται δύσκολη, με ελάχιστες σωστές προβλέψεις, υπογραμμίζοντας ζητήματα με το μέγεθος του δείγματος και τη ιδιαιτερότητα των χαρακτηριστικών. Η NonDementia δείχνει τη δύναμη του μοντέλου, παρά τη σύγχυση με τα ηπιότερα στάδια. Η αντίχνευση VeryMildDementia είναι σχετικά ακριβής, ωστόσο οι εσφαλμένες ταξινομήσεις ως NonDementia αντικατοπτρίζουν προκλήσεις διαφοροποίησης. Η μήτρα υπογραμμίζει την επάρκεια του μοντέλου με το NonDementia και το VeryMildDementia, αλλά επισημαίνει σημαντική σύγχυση μεταξύ MildDementia και VeryMildDementia, καθώς και μια αξιοσημείωτη δυσκολία με την ModerateDementia.

Leaky ReLU: Πίνακας μετρήσεων απόδοσης κατά κατηγορία

- Χρησιμοποιώντας τη συνάρτηση ενεργοποίησης Leaky ReLU, το μοντέλο εμφανίζει μεταβλητή απόδοση σε όλα τα στάδια άνοιας (βλ. *Πίνακας 4.4.*). Η MildDementia εμφανίζει μέτρια επαναληψιμότητα (0,65) και χαμηλότερη ανάκληση (0,55), με ισορροπημένη βαθμολογία F1 (0,60), υποδεικνύοντας κάποια ικανότητα στην πρόβλεψη της τάξης αλλά περιθώριο βελτίωσης στην αντίχνευση. Η ModerateDementia παραμένει πρόκληση, με πολύ χαμηλή επαναληψιμότητα (0,25) και ανάκληση (0,08), με αποκορύφωμα την ελάχιστη βαθμολογία F1 (0,12). Αυτό υπογραμμίζει τη δυσκολία στην εκμάθηση των διακριτικών χαρακτηριστικών αυτής της κλάσης, που πιθανώς επιδεινώνεται από ένα μικρό μέγεθος δείγματος. Η NonDementia επιτυγχάνει την υψηλότερη βαθμολογία F1 (0,78), αντικατοπτρίζοντας ισχυρά ποσοστά πρόβλεψης και αναγνώρισης. Το VeryMildDementia έχει αρκετά υψηλή επαναληψιμότητα (0,69) αλλά χαμηλότερη ανάκληση (0,54), υποδηλώνοντας μια αξιοπρεπή ακρίβεια πρόβλεψης. Η συνολική ακρίβεια 0,70 υποδηλώνει σταθερή απόδοση, ωστόσο ο

μέσος όρος μακρόμεσης βαθμολογίας F1 (0,53) δείχνει ανισορροπίες στην εμπιστοσύνη στην πρόβλεψη της κατηγορίας.

Leaky ReLU: Καμπύλες ROC & Επαναληψιμότητας – Ανάκλησης

- Χρησιμοποιώντας την ενεργοποίηση Leaky ReLU, οι καμπύλες ROC του μοντέλου (βλ. *Εικ. 4.8.*) υποδεικνύουν ισχυρή διακριτική ικανότητα σε όλες τις κατηγορίες άνοιας, με ιδιαίτερα υψηλές βαθμολογίες AUC για MildDementia (0,89) και ModerateDementia (0,90). Αυτές οι βαθμολογίες υποδηλώνουν εξαιρετική εμπιστοσύνη μοντέλου για τη διάκριση αυτών των καταστάσεων, αν και το μικρό μέγεθος δείγματος για την ModerateDementia απαιτεί προσεκτική ερμηνεία. Η AUC για NonDementia (0,84) και VeryMildDementia (0,78) αντικατοπτρίζει επίσης σταθερή δυνατότητα διαχωρισμού, αν και ελαφρώς χαμηλότερη από τις προηγούμενες κατηγορίες. Η ανάλυση Επαναληψιμότητας-Ανάκλησης (βλ. *Εικ. 4.9.*) συμπληρώνει περαιτέρω αυτά τα ευρήματα, με το NonDementia να δείχνει ανώτερη επαναληψιμότητας και ισορροπία ανάκλησης (AP = 0,83), που υποδηλώνει την αποτελεσματικότητα του μοντέλου στην ταξινόμηση των περιπτώσεων NonDementia. Ωστόσο, η ModerateDementia (AP = 0,16) και η MildDementia (AP = 0,62) παρουσιάζουν προκλήσεις στη διατήρηση της επαναληψιμότητας με αυξημένη ανάκληση, υπογραμμίζοντας τη δυσκολία του μοντέλου να προβλέψει με ακρίβεια αυτές τις κατηγορίες.

Leaky ReLU: Οπτικοποίηση Grad-CAM

- Οι οπτικοποιήσεις Grad-CAM για την ενεργοποίηση Leaky ReLU (βλ. *Εικ. 4.10.*) αποκαλύπτουν ένα χαρακτηριστικό μοτίβο ενεργοποίησης, με αξιοσημείωτη έμφαση στην περιφέρεια, την κεντρική αύλακα και τις οπίσθιες περιοχές του εγκεφάλου. Αυτό το μοτίβο υπογραμμίζει την προσοχή του μοντέλου στον βρεγματικό λοβό, τον νησιωτικό φλοιό και την κυκλική έλικα [109], ευθυγραμμίζοντας με την κατανόηση ότι αυτές οι περιοχές είναι ζωτικής σημασίας στο πλαίσιο της άνοιας. Η οπτικοποίηση δείχνει επίσης έντονη ενεργοποίηση στο αριστερό ημισφαίριο, υποδεικνύοντας μια πλευρική εστίαση στην ανάλυση του μοντέλου. Είναι ενδιαφέρον ότι ορισμένες εικόνες παρουσιάζουν διάχυτη και ασθενέστερη ενεργοποίηση στον εγκεφαλο, υποδηλώνοντας περιπτώσεις όπου η εστίαση του μοντέλου είναι λιγότερο στοχευμένη.

Συμπέρασμα απόδοσης μοντέλου με συνάρτηση ενεργοποίησης Leaky ReLU

- Χρησιμοποιώντας την ενεργοποίηση Leaky ReLU, το μοντέλο παρουσιάζει αξιόπαινες δυνατότητες γενίκευσης με σταθερά αποτελέσματα στις περισσότερες μετρήσεις απόδοσης, ιδιαίτερα για τις κατηγορίες NonDementia και VeryMildDementia. Η ικανότητα του μοντέλου να διαφοροποιεί τα στάδια της άνοιας με υψηλές τιμές AUC για όλες τις τάξεις υποδηλώνει αποτελεσματική μάθηση. Ωστόσο, οι προκλήσεις εξακολουθούν να υφίστανται, ειδικά όσον αφορά την ακριβή ταξινόμηση της ModerateDementia, πιθανόν λόγω της περιορισμένης αναπαράστασής της στο δείγμα. Η μήτρα σύγχυσης και οι αναφορές ταξινόμησης υποδεικνύουν την επάρκεια του μοντέλου σε περιπτώσεις NonDementia, αλλά αποκαλύπτουν δυσκολίες με την MildDementia, που συχνά συγχέεται με την VeryMildDementia. Οι καμπύλες ROC και επαναληψιμότητας-ανάκλησης ενισχύουν τη διακριτική δύναμη του μοντέλου, αλλά υπογραμμίζουν την ανάγκη για βελτίωση σε ειδικές προβλέψεις κατηγορίας. Οι οπτικοποιήσεις Grad-CAM υποδηλώνουν εστιασμένη προσοχή σε βιολογικά σχετικές περιοχές του εγκεφάλου, υποδεικνύοντας ένα στοχευμένο αλλά κάπως ασυνεπές μοτίβο μάθησης.

5.3.Σχολιασμός αποτελεσμάτων συνάρτησης PReLU

PReLU: Αρχείο καταγραφής

- Οι έντονες αιχμές στην απώλεια επικύρωσης (βλ. *Εικ. 4.11.*) υποδηλώνουν περαιτέρω ασυνεπή μάθηση ή ετερογένεια δεδομένων. Σημαντικές διακυμάνσεις στην επαναληψιμότητα και την ανάκληση εντός του συνόλου επικύρωσης υπογραμμίζουν τη μεταβλητή εμπιστοσύνη και πρόκληση του μοντέλου στη διατήρηση συνεπούς θετικής ταυτοποίησης. Η ασταθής τάση στην απώλεια Hamming επικύρωσης, σε αντίθεση με τη βελτίωση του σετ εκπαίδευσης, εγείρει ανησυχίες σχετικά με την αξιοπιστία του μοντέλου σε αόρατες προβλέψεις δεδομένων (βλ. *Πίνακας 4.5.*). Η μέτρια ακρίβεια 56,29% του σετ ελέγχου, σε συνδυασμό με συγκρίσιμα στοιχεία επαναληψιμότητας και ανάκλησης, υποδηλώνει την ανάγκη για ουσιαστική βελτίωση στην ακρίβεια πρόβλεψης κατηγορίας. Η μέτρια AUC 78,25% και η υψηλή απώλεια Hamming 27,45% τονίζουν την κρίσιμη ανάγκη για βελτίωση, ιδιαίτερα σε εφαρμογές που απαιτούν υψηλή ακρίβεια. Αυτό το μοντέλο, επομένως, παρουσιάζει μέτρια απόδοση με άφθονα περιθώρια αντιμετώπισης της υπερπροσαρμογής και ενίσχυσης της γενίκευσης.

PReLU: Μήτρα Σύγχυσης

- Αναλύοντας την ανίχνευση άνοιας μέσω μιας μήτρας σύγχυσης, το μοντέλο PReLU (βλ. *Εικ. 4.12.*) παρουσιάζει μικτές επιδόσεις. Οι σωστές προβλέψεις για την MildDementia είναι χαμηλές, με σημαντική σύγχυση με την VeryMildDementia, υποδηλώνοντας δυσκολία στον αποχωρισμό. Το ModerateDementia δεν βλέπει σωστές προβλέψεις, υπογραμμίζοντας σοβαρές προκλήσεις λόγω περιορισμένων δεδομένων. Το NonDementia προσδιορίζεται με ακρίβεια, αν και με κάποια σύγχυση με το VeryMildDementia, υποδηλώνοντας ελαφρά προβλήματα διαφοροποίησης. Η VeryMildDementia ανιχνεύεται αρκετά καλά, αλλά συχνά συγχέεται με την NonDementia. Η μήτρα αποκαλύπτει την ισχυρότερη απόδοση του μοντέλου στην αναγνώριση της NonDementia, ωστόσο δυσκολεύεται σημαντικά με τη διάκριση μεταξύ των σταδίων άνοιας, ειδικά μεταξύ MildDementia και VeryMildDementia, και αντιμετωπίζει περιορισμούς στην αναγνώριση της ModerateDementia λόγω λιγοστών δεδομένων.

PReLU: Πίνακας μετρήσεων απόδοσης κατά κατηγορία

- Η MildDementia αναγνωρίζεται με επαναληψιμότητα 0,65 (βλ. *Πίνακας 4.6.*) αλλά χαμηλή ανάκληση 0,18, που οδηγεί σε ένα απογοητευτικό σκορ F1 (0,29). Το μοντέλο αποτυγχάνει τελείως να αναγνωρίσει περιπτώσεις ModerateDementia, επισημαίνοντας σημαντικούς περιορισμούς λόγω του μικρού μεγέθους δείγματος. Η NonDementia προβλέπεται επαρκώς, με ισορροπημένη επαναληψιμότητα και ανάκληση (0,67), με αποτέλεσμα τη βαθμολογία F1 να είναι 0,67. Η VeryMildDementia, ωστόσο, παρουσιάζει χαμηλότερη επαναληψιμότητα (0,44) και μέτρια ανάκληση (0,58), με βαθμολογία F1 0,50. Συνολικά, η επαναληψιμότητα του μοντέλου ανέρχεται στο 0,56, με αξιοσημείωτα χαμηλό μέσο όρο μακρόμεσης βαθμολογίας F1 (0,36), υποδηλώνοντας σημαντικά πεδία βελτίωσης, ιδιαίτερα στη γενίκευση σε όλες τις κατηγορίες.

PReLU: Καμπύλες ROC & Επαναληψιμότητας – Ανάκλησης

- Οι κατηγορίες MildDementia και ModerateDementia παρουσιάζουν καλή δυνατότητα διαχωρισμού με AUC 0,77 και 0,82 (βλ. *Εικ. 4.13.*), αντίστοιχα, αν και αυτοί οι αριθμοί έρχονται σε αντίθεση με την κακή επαναληψιμότητα και ανάκληση του μοντέλου, ιδιαίτερα για την ModerateDementia. Αυτή η απόκλιση υπογραμμίζει την πολυπλοκότητα του να βασίζεται κανείς αποκλειστικά στην

AUC σε περιπτώσεις αραιών δεδομένων. Η NonDementia και η VeryMildDementia, με AUC 0,73 και 0,64, παρουσιάζουν ποικίλη αποτελεσματικότητα, με τη NonDementia να αναγνωρίζεται με μεγαλύτερη ακρίβεια από την VeryMildDementia. Η ανάλυση Επαναληψιμότητας – Ανάκλησης σκιαγραφεί περαιτέρω τις αποχρώσεις απόδοσης του μοντέλου, υποδεικνύοντας μια ισχυρότερη ικανότητα πρόβλεψης για NonDementia (AP = 0,73) σε σχέση με άλλες κατηγορίες (βλ. *Εικ. 4.14.*). Η ιδιαίτερα χαμηλή βαθμολογία AP του ModerateDementia (0,03) υπογραμμίζει σημαντικές προκλήσεις πρόβλεψης, που επιδεινώνονται από τα περιορισμένα μεγέθη δειγμάτων.

PReLU: Οπτικοποίηση Grad-CAM

- Οι οπτικοποιήσεις Grad-CAM (βλ. *Εικ. 4.15.*) για τη συνάρτηση ενεργοποίησης PReLU παρουσιάζουν σταθερά ισχυρή ενεργοποίηση στην περιφέρεια του φλοιού του εγκεφάλου και στις κεντρικές περιοχές. Αυτό το μοτίβο επαναλαμβανόμενης ενεργοποίησης υποδηλώνει την εστίαση του μοντέλου στην ατροφία του φλοιού και στις κεντρικές δομές του εγκεφάλου, όπως οι κοιλίες, η έλικα, ο κερκοφόρος πυρήνας και τα βασικά γάγγλια, που είναι κρίσιμα στην παθολογία της άνοιας [108][109]. Επιπλέον, ο μετωπιαίος και ο βρεγματικός λοβός, που είναι γνωστό ότι επηρεάζονται στην άνοια, επισημαίνονται συχνά, υποδεικνύοντας την ευθυγράμμιση του μοντέλου με κλινικά σχετικά χαρακτηριστικά για την ταξινόμηση της άνοιας. Ωστόσο, οι περιοχές που απεικονίζονται με ψυχρότερους τόνους, που αντιπροσωπεύουν χαμηλότερα επίπεδα ενεργοποίησης, δείχνουν περιοχές που θεωρούνται λιγότερο κρίσιμες από το μοντέλο.

Συμπέρασμα απόδοσης μοντέλου με συνάρτηση ενεργοποίησης PReLU

- Παρά την επίτευξη σταθερού υψηλού AUC και τη μείωση της απώλειας εκπαίδευσης, το μοντέλο παλεύει με τη γενίκευση σε νέα δεδομένα, όπως υποδεικνύεται από τις διακυμάνσεις στις μετρήσεις επικύρωσης. Οι πιο σημαντικές προκλήσεις προκύπτουν στις προβλέψεις της κλάσης, ιδιαίτερα για τη ModerateDementia, όπου δεν έγιναν σωστές ταυτοποιήσεις, αντανακλώντας ζητήματα με το μέγεθος του δείγματος και το βάθος μάθησης. Η ασυνεπής εμπιστοσύνη πρόβλεψης του μοντέλου σε όλες τις τάξεις, ειδικά με υψηλό ψευδώς θετικό ποσοστό για MildDementia, δείχνει αναποτελεσματικότητα στην αποτύπωση διακριτικών χαρακτηριστικών. Οι αναλύσεις καμπυλών ROC και PR υποδηλώνουν μειωμένη διακριτική ικανότητα σε σύγκριση με το Leaky ReLU, με τις καμπύλες PR να υπογραμμίζουν μια επισφαλή ισορροπία επαναληψιμότητας και ανάκλησης. Οι οπτικοποιήσεις Grad-CAM παρέχουν μικτές πληροφορίες, υποδεικνύοντας τόσο σχετική όσο και δυνητικά θορυβώδη εστίαση χαρακτηριστικών.

5.4.Σχολιασμός αποτελεσμάτων συνάρτησης ELU

ELU: Αρχείο καταγραφής

- Η υψηλή και σταθερή AUC εκπαίδευσης του μοντέλου, μαζί με τη συγκλίνουσα AUC επικύρωσης (βλ. *Εικ. 4.16.*), προαναγγέλλει τις δυνατότητες γενίκευσης. Η συνεχής μείωση της απώλειας εκπαίδευσης και η σταδιακή σταθεροποίηση της απώλειας επικύρωσης επιβεβαιώνουν τη βελτίωση των προβλέψεων του μοντέλου με την πάροδο του χρόνου. Οι μετρήσεις επαναληψιμότητας και ανάκλησης, που ξεκινούν από ψηλά και αντικατοπτρίζονται στενά μεταξύ τους κατά τη διάρκεια των epochs, προτείνουν ακριβείς θετικές προβλέψεις και βελτιώνουν τον προσδιορισμό συνάφειας στο σύνολο επικύρωσης. Η σημαντική μείωση της απώλειας εκπαίδευσης και η σταθεροποίησή της σε χαμηλότερο επίπεδο

επικύρωσης αντικατοπτρίζουν θετικά την προγνωστική ακρίβεια του μοντέλου. Αξιολογώντας το σύνολο δοκιμών (βλ. Πίνακας 4.7.), σημειώνεται ποσοστό ακρίβειας 64,74%, με επαναληψιμότητα και ανάκληση στενά ευθυγραμμισμένες, υποδεικνύοντας σταθερές δυνατότητες πρόβλεψης. Μια βαθμολογία AUC 84,70% και απώλεια Hamming 22,03% αντιπροσωπεύουν μια ισχυρή ικανότητα διαφοροποίησης κατηγορίας με λιγότερες εσφαλμένες προβλέψεις σε σύγκριση με το μοντέλο PReLU.

ELU: Μήτρα Σύγχυσης

- Η MildDementia θέτει σημαντικές προκλήσεις, με πολλές περιπτώσεις να ταξινομούνται εσφαλμένα ως VeryMildDementia ή NonDementia, υποδεικνύοντας προβλήματα διαφοροποίησης (βλ. Εικ. 4.17.). Η ModerateDementia είναι η λιγότερο ακριβής προβλεπόμενη τάξη, αντικατοπτρίζοντας τον αντίκτυπο των μικρών μεγεθών δείγματος στη μάθηση μοντέλων. Η NonDementia ξεχωρίζει για το μοντέλο, επιδεικνύοντας υψηλή ακρίβεια παρά ορισμένες εσφαλμένες ταξινομήσεις, γεγονός που υποδηλώνει μικρή σύγχυση με ηπιότερα στάδια άνοιας. Η VeryMildDementia αναγνωρίζεται σωστά σε εύλογο βαθμό, αν και η σύγχυση με την NonDementia υποδηλώνει τομείς για βελτίωση.

ELU: Πίνακας μετρήσεων απόδοσης κατά κατηγορία

- Χρησιμοποιώντας τη λειτουργία ενεργοποίησης ELU (βλ. Πίνακας 4.8.), το μοντέλο επιδεικνύει ποικίλη αποτελεσματικότητα σε διαφορετικά στάδια άνοιας. Η MildDementia έχει υψηλή επαναληψιμότητα (0,71) αλλά χαμηλή ανάκληση (0,27), με αποτέλεσμα ένα μέτριο σκορ F1 (0,40). Η ModerateDementia δείχνει τέλεια επαναληψιμότητα (1,00) αλλά σοβαρά περιορισμένη ανάκληση (0,17), αντανακλώντας τον αντίκτυπο του μικρού μεγέθους δείγματος της κλάσης. Η NonDementia είναι το προπύργιο του μοντέλου, με ισορροπημένη επαναληψιμότητα (0,71) και ανάκληση (0,78) και την υψηλότερη βαθμολογία F1 (0,74). Η VeryMildDementia παρουσιάζει μέτρια επαναληψιμότητα (0,55) και ανάκληση (0,63), με βαθμολογία F1 0,59. Η συνολική ακρίβεια 0,65 και η μακρόμεση βαθμολογία F1 0,50 υποδηλώνουν μια δίκαιη ικανότητα στον εντοπισμό της NonDementia και της VeryMildDementia, αλλά αντιμετωπίζει δυσκολίες σε πιο σοβαρά στάδια άνοιας λόγω περιορισμών δεδομένων.

ELU: Καμπύλες ROC & Επαναληψιμότητας – Ανάκλησης

- Η αποτελεσματικότητα της συνάρτησης ενεργοποίησης ELU στην ταξινόμηση σταδίων άνοιας αξιολογείται μέσω καμπυλών ROC (βλ. Εικ. 4.18.), επιδεικνύοντας καλή δυνατότητα διαχωρισμού σε όλες τις κατηγορίες με βαθμολογίες AUC που κυμαίνονται από 0,75 για VeryMildDementia έως 0,82 για ModerateDementia. Αυτές οι βαθμολογίες υποδηλώνουν μια ισχυρή ικανότητα μοντέλου στη διάκριση μεταξύ των συνθηκών, αν και με μια προσεκτική ερμηνεία για τη ModerateDementia λόγω μικρών μεγεθών δείγματος. Οι Καμπύλες PR (βλ. Εικ. 4.19.) συμπληρώνουν αυτά τα ευρήματα, υπογραμμίζοντας ιδιαίτερα την ισχυρή απόδοση του μοντέλου στις προβλέψεις για NonDementia (AP = 0,80) και τη μέτρια επιτυχία στην VeryMildDementia (AP = 0,59). Το χαμηλότερο AP για τη ModerateDementia (AP = 0,33) αντικατοπτρίζει τις συνεχιζόμενες προκλήσεις στην ακριβή ταξινόμηση, υπονοώντας τον αντίκτυπο των περιορισμένων δεδομένων.

ELU: Οπτικοποίηση Grad-CAM

- Οι οπτικοποιήσεις Grad-CAM της συνάρτησης ενεργοποίησης ELU (βλ. Εικ. 4.20.) παρουσιάζουν ένα μικτό σενάριο όπου οι περιπτώσεις χαμηλής ενεργοποίησης έχουν αυξηθεί σημαντικά, υποδηλώνοντας τις προκλήσεις του

μοντέλου στον συνεπή εντοπισμό κρίσιμων περιοχών για την εργασία ταξινόμησης. Παρόλα αυτά, υπάρχουν περιπτώσεις έντονης ενεργοποίησης στον μετωπιαίο και βρεγματικό λοβό, που ευθυγραμμίζονται με περιοχές που είναι γνωστό ότι επηρεάζονται από την άνοια. Ωστόσο, ενεργοποιήσεις που εκτείνονται πέρα από αυτούς τους τομείς ενδιαφέροντος υποδηλώνουν την ευαισθησία του μοντέλου στο θόρυβο, επηρεάζοντας δυνητικά την αποτελεσματικότητά του στη μάθηση. Σε σύγκριση με τις ενεργοποιήσεις ReLU, Leaky ReLU και PReLU, η ενεργοποίηση ELU δείχνει ένα γενικά ασθενέστερο μοτίβο ενεργοποίησης, υποδεικνύοντας έναν πιθανό περιορισμό στην ικανότητα του μοντέλου να χαρακτηρίζει σθεναρά σχετικά χαρακτηριστικά σε διαφορετικές περιπτώσεις.

Συμπέρασμα απόδοσης μοντέλου με συνάρτηση ενεργοποίησης ELU

- Η εφαρμογή της συνάρτησης ενεργοποίησης ELU στο μοντέλο παρουσιάζει μια διαφοροποιημένη εικόνα της αποτελεσματικότητάς της κατάταξης. Η καλή γενίκευση αποδεικνύεται από την ευθυγράμμιση των AUC εκπαίδευσης και επικύρωσης, παράλληλα με την αποτελεσματική μάθηση που υποδεικνύεται από τις καμπύλες απώλειας. Το μοντέλο επιτυγχάνει λογικές μετρήσεις απόδοσης στο δοκιμαστικό σύνολο, με αξιοσημείωτη AUC 84,70%, υποδηλώνοντας μια αξιόπιστη διάκριση μεταξύ των κλάσεων. Ωστόσο, οι επιδόσεις ανά κατηγορία ποικίλλουν, με σημαντικές προκλήσεις στην ακριβή πρόβλεψη της MildDementia και της ModerateDementia, η τελευταία επιδεινώνεται από τους περιορισμούς των δεδομένων. Μια απώλεια Hamming περίπου 22% σηματοδοτεί μια βελτίωση σε σχέση με το PReLU, αλλά εξακολουθεί να δείχνει σημαντικές ανακρίβειες προβλέψεων. Οι αναλύσεις ROC και ανάκλησης επαναληψιμότητας αντικατοπτρίζουν τη σταθερή απόδοση του μοντέλου για τη NonDementia, ωστόσο υπογραμμίζουν την ανάγκη για βελτιώσεις στην ταξινόμηση της ModerateDementia. Οι οπτικοποιήσεις Grad-CAM υποδηλώνουν πιθανά προβλήματα εστίασης, με τις αυξημένες περιοχές χαμηλής ενεργοποίησης να υποδηλώνουν την ανάγκη για πιο ακριβή αναγνώριση χαρακτηριστικών.

5.5.Σχολιασμός γραφημάτων σύγκρισης μεταξύ των συναρτήσεων ενεργοποίησης

Γράφημα σύγκρισης AUC μεταξύ συναρτήσεων ενεργοποίησης

Κατά την εξερεύνηση των συναρτήσεων ενεργοποίησης μέσα σε ένα μοντέλο CNN, προκύπτουν διακριτά χαρακτηριστικά, ιδιαίτερα στο πλαίσιο της αρχικής ταχύτητας εκμάθησης, της σταθερότητας της μάθησης και της ικανότητας του μοντέλου να γενικεύει με την πάροδο του χρόνου. Η ενεργοποίηση PReLU δείχνει μια αξιοσημείωτη αρχική αύξηση στην AUC, που σημαίνει ταχεία έναρξη της μάθησης. Αυτή η γρήγορη ανάβαση, ωστόσο, πλατώνει νωρίτερα από τις αντίστοιχες, υπονοώντας πιθανή πρόωμη σύγκλιση ή υπερπροσαρμογή, όπου η ικανότητα γενίκευσης του μοντέλου αρχίζει να μειώνεται (βλ. *Εικ. 4.21*).

Αντίστροφα, η ενεργοποίηση της ELU συνδυάζει τα οφέλη της γρήγορης αρχικής εκμάθησης με παρατεταμένη βελτίωση, ξεπερνώντας το PReLU στη διάρκεια πριν από το πλάτωμα. Αυτό το μοτίβο υποδηλώνει ότι η ELU όχι μόνο μαθαίνει γρήγορα, αλλά διατηρεί επίσης αυτή την ορμή, ενισχύοντας δυνητικά ανώτερες δυνατότητες γενίκευσης καθώς πλησιάζει στην κορυφαία απόδοσή της. Το Leaky ReLU, με την πιο μέτρια άνοδό του, ενσωματώνει μια σταδιακή προσέγγιση εκμάθησης. Η πρόοδός του εκτείνεται σε μεγαλύτερο αριθμό epochs σε σύγκριση με το PReLU, υπονοώντας μια πιο συνεπή και σταθερή πορεία μάθησης, αν και με πιο αργή εκκίνηση. Αυτή η σταθερή πρόοδος μπορεί να υποδηλώνει μια μεθοδική εξαγωγή πληροφοριών, επωφελής για τη μακροπρόθεσμη ευρωστία του μοντέλου. Η

ενεργοποίηση ReLU ξεχωρίζει για την ήπια κλίση της, σημειώνοντας τον χαμηλότερο αρχικό ρυθμό εκμάθησης μεταξύ της ομάδας. Ωστόσο, η απόδοσή της βελτιώνεται σταδιακά σε όλη την πιο εκτεταμένη περίοδο των epochs, υποδηλώνοντας μια διαρκή ικανότητα συλλογής πολύτιμων πληροφοριών από τα δεδομένα. Αυτή η παρατεταμένη φάση μάθησης υπογραμμίζει τις δυνατότητες του ReLU για βαθιά, διαρκή μάθηση, η οποία μπορεί να μην πλατειάσει εντός του εύρους του παρατηρούμενου epoch, υποδεικνύοντας χώρο για περαιτέρω ανάπτυξη. Καθώς όλες οι συναρτήσεις ενεργοποίησης είναι αναπόφευκτα πλατειασμένες, αντανακλώντας μια σύγκλιση στη βέλτιστη απόδοσή τους, αυτή η φάση σηματοδοτεί μια κρίσιμη καμπή στην εκπαίδευση μοντέλων. Συγκεκριμένα, το πλάτωμα του ReLU καθυστερεί, γεγονός που υποδηλώνει ότι η εκτεταμένη εκπαίδευση θα μπορούσε να αποφέρει πρόσθετα οφέλη. Στην τελική αξιολόγηση των τιμών AUC, το PReLU προηγείται στιγμιαία, υποδηλώνοντας ένα ισχυρό αλλά ίσως πρόωρα περιορισμένο δυναμικό μάθησης. Αυτό ακολουθείται στενά από το ELU, μετά το Leaky ReLU, με το ReLU μετά το τέλος, αν και οι τελικές βαθμολογίες AUC παρέχουν ένα κρίσιμο σημείο αναφοράς απόδοσης, υπογραμμίζοντας την ικανότητα κάθε συνάρτησης να διακρίνει αποτελεσματικά τις κλάσεις.

Αυτές οι παρατηρήσεις έχουν σημαντικές επιπτώσεις στην επιλογή μοντέλου, υπογραμμίζοντας τον αντίκτυπο της επιλογής της συνάρτησης ενεργοποίησης στη δυναμική μάθησης. Οι ενεργοποιήσεις γρήγορης εκμάθησης όπως το PReLU και το ELU προσφέρουν πλεονεκτήματα για γρήγορη επανάληψη και πρώιμη επικύρωση μοντέλου. Αντίθετα, οι ενεργοποιήσεις που υποστηρίζουν τη βιώσιμη μάθηση, όπως το ReLU και το Leaky ReLU, είναι προτιμότερες για σενάρια που επιτρέπουν εκτεταμένες περιόδους εκπαίδευσης, που ενδεχομένως οδηγούν σε πιο ισχυρή γενίκευση. Ωστόσο, η γρήγορη άνοδος και το πρώιμο πλάτωμα που χαρακτηρίζουν το PReLU σηκώνουν σημαίες για υπερπροσαρμογή, απαιτώντας στρατηγικές όπως η τακτοποίηση για τον μετριασμό αυτού του κινδύνου. Εν τω μεταξύ, η συνεχής βελτίωση της απόδοσης της ELU χωρίς επακόλουθη μείωση της AUC υποδηλώνει ικανότητα περαιτέρω μάθησης, πιθανώς μέσω πρόσθετων epochs ή ενσωμάτωσης δεδομένων.

Γράφημα σύγκρισης απώλειας μεταξύ συναρτήσεων ενεργοποίησης

Η ενεργοποίηση PReLU διακρίνεται με μια αξιοσημείωτη απότομη αρχική μείωση της απώλειας, που σηματοδοτεί μια γρήγορη βελτίωση στις προβλέψεις μοντέλων στην αρχή της εκπαίδευσης. Αυτή η απότομη πτώση υποδηλώνει ταχεία πρώιμη μάθηση, αν και υποδηλώνει επίσης μια τάση για πρώιμο επίπεδο, η οποία μπορεί να εγείρει ανησυχίες σχετικά με την ικανότητα του μοντέλου να συνεχίσει να γενικεύει αποτελεσματικά (βλ. *Εικ. 4.22*).

Αντίστροφα, η ενεργοποίηση ELU παρουσιάζει μια παρόμοια γρήγορη έναρξη μείωσης των απωλειών, ωστόσο επεκτείνει αυτή τη φάση βελτίωσης σε πιο εκτεταμένη περίοδο σε σύγκριση με το PReLU. Αυτή η διαρκής μείωση υποδηλώνει ότι η ELU όχι μόνο ξεκινά τη μάθηση γρήγορα, αλλά διατηρεί επίσης έναν σταθερό ρυθμό βελτίωσης, ενισχύοντας ενδεχομένως ένα βαθύτερο επίπεδο γενίκευσης καθώς προχωρά. Το Leaky ReLU, με την πιο μέτρια και συνεπή κάθοδο στην απώλεια, δίνει μια εικόνα σταθερής, σταδιακής μάθησης. Αυτή η σταδιακή προσέγγιση υποδεικνύει μια σταθερή αφομοίωση πληροφοριών, συμβάλλοντας ενδεχομένως σε μια πιο ισχυρή απόδοση του μοντέλου με την πάροδο του χρόνου, αν και χωρίς την αρχική ταχύτητα που παρατηρείται στο PReLU και στο ELU. Η ενεργοποίηση ReLU, που χαρακτηρίζεται από την πιο ήπια κλίση μεταξύ της ομάδας, σηματοδοτεί την πιο αργή αρχική μείωση της απώλειας. Η παρατηρούμενη πτώση της απώλειας σε όλες τις

συναρτήσεις ενεργοποίησης σηματοδοτεί ένα κοινό όριο όπου τα μοντέλα προσεγγίζουν τη βέλτιστη απόδοσή τους, αν και σε διαφορετικά epochs. Σημειωτέων, το PReLU και το ELU φτάνουν σε αυτό το πλάτωμα νωρίτερα από το Leaky ReLU και το ReLU, υποδεικνύοντας διακυμάνσεις στο πόσο γρήγορα κάθε μοντέλο εξαντλεί τις δυνατότητες εκμάθησής του, δεδομένης της ίδιας αρχιτεκτονικής και δεδομένων.

Οι τιμές τελικής απώλειας διευκρινίζουν περαιτέρω τον αντίκτυπο της επιλογής της λειτουργίας ενεργοποίησης στην εκπαίδευση μοντέλων, με το PReLU να επιτυγχάνει τη χαμηλότερη τελική απώλεια, ακολουθούμενο από τα Leaky ReLU, ELU και ReLU. Αυτά τα αποτελέσματα υποδηλώνουν ότι ενώ η ταχεία μείωση των απωλειών μπορεί να είναι επωφελής, ειδικά σε περιβάλλοντα με περιορισμένο χρόνο, μια πιο σκόπιμη και διαρκής μείωση μπορεί να είναι προτιμότερη για την επίτευξη ευρύτερης γενίκευσης του μοντέλου. Ωστόσο, η ταχεία πτώση που παρατηρείται με το PReLU θέτει ενδείξεις για πιθανή υπερπροσαρμογή, ειδικά εάν τέτοιες τάσεις δεν αντικατοπτρίζονται στην απώλεια επικύρωσης. Αυτό υπογραμμίζει τη σημασία της επαγρύπνησης και, ενδεχομένως, της ενσωμάτωσης μέτρων όπως η τακτοποίηση για τον μετριασμό του κινδύνου υπερπροσαρμογής. Ενώ οι γρήγορες στην εκπαίδευσή τους, PReLU και ELU, προσφέρουν τη γοητεία της ταχείας προόδου, η διαρκής και συνεπής μάθηση που παρουσιάζεται από τη Leaky ReLU και τη ReLU μπορεί να αποφέρει οφέλη όσον αφορά τη γενίκευση του μοντέλου και τη μακροπρόθεσμη απόδοση.

Καμπύλες ROC & Επαναληψιμότητας – Ανάκλησης για τη κατηγορία MildDementia (Ηπια Άνοια)

Η ανάλυση της ικανότητας του μοντέλου να προσδιορίζει την κατηγορία MildDementia μέσω τόσο των καμπυλών ROC όσο και PR αποφέρει διορατικά συμπεράσματα σχετικά με την αποτελεσματικότητα των διαφόρων λειτουργιών ενεργοποίησης. Η ανάλυση της καμπύλης ROC παρέχει μια σαφή ένδειξη της διακριτικής ικανότητας του μοντέλου μεταξύ της κατηγορίας MildDementia και άλλων, με την τιμή AUC να χρησιμεύει ως σημείο αναφοράς για την απόδοση. Μεταξύ των συναρτήσεων ενεργοποίησης που αξιολογήθηκαν, η Leaky ReLU (πορτοκαλί γραμμή) αναδεικνύεται ως η πιο ικανή, επιτυγχάνοντας την υψηλότερη AUC και επιδεικνύοντας έτσι ανώτερη αποτελεσματικότητα στη διάκριση της κατηγορίας MildDementia (βλ. *Εικ. 4.23.*). Η ELU (κόκκινη γραμμή) ακολουθεί πιστά, υποδεικνύοντας αξιόπαινη απόδοση, αν και ελαφρώς μικρότερη από την Leaky ReLU. Συγκριτικά, η PReLU (πράσινη γραμμή) και η ReLU (μπλε γραμμή) καταγράφουν χαμηλότερες τιμές AUC, τοποθετώντας τη ReLU ως το λιγότερο αποτελεσματική σε αυτό το συγκεκριμένο πλαίσιο.

Συμπληρώνοντας αυτό, η ανάλυση καμπύλης PR μετατοπίζει την εστίαση στην επαναληψιμότητα και την ανάκληση του μοντέλου σχετικά με την κατηγορία MildDementia, ιδιαίτερα πολύτιμη στο πλαίσιο μη ισορροπημένων συνόλων δεδομένων. Αντηχώντας τα ευρήματα της καμπύλης ROC, η Leaky ReLU ξεχωρίζει και πάλι, επιδεικνύοντας την υψηλότερη επαναληψιμότητα σε όλα τα επίπεδα ανάκλησης. Αυτό υποδηλώνει ότι η Leaky ReLU όχι μόνο προσδιορίζει με ακρίβεια την κατηγορία MildDementia, αλλά το κάνει επίσης με μεγάλη εμπιστοσύνη στις προβλέψεις της. Η ELU διατηρεί μια τροχιά απόδοσης παρόμοια με αυτή της Leaky ReLU, αν και με οριακά χαμηλότερη επαναληψιμότητα, καθιστώντας τη τη δεύτερη πιο αποτελεσματική ενεργοποίηση για την κατηγορία MildDementia. Η PReLU και η ReLU, αντίθετα, παρουσιάζουν μειωμένη ακρίβεια, υποδεικνύοντας μια λιγότερο

αξιόπιστη ικανότητα πρόβλεψης για την κατηγορία MildDementia, με τη ReLU να υστερεί έναντι των άλλων.

Η ενσωμάτωση πληροφοριών από τις καμπύλες ROC και PR προσφέρει μια ολοκληρωμένη κατανόηση της απόδοσης του μοντέλου σε διαφορετικές μετρήσεις. Ενώ οι καμπύλες ROC υπογραμμίζουν τη συνολική ικανότητα του μοντέλου να διαχωρίζει κατηγορίες, οι καμπύλες PR εμβαθύνουν στη δυναμική ακρίβειας και ανάκλησης του μοντέλου, ιδιαίτερα σχετικές με θετικά λοξές κλάσεις σε μη ισορροπημένα σύνολα δεδομένων. Η εξαιρετική απόδοση της Leaky ReLU και στις δύο αναλύσεις υπογραμμίζει την ανώτερη ισορροπία μεταξύ ευαισθησίας και ειδικότητας, καθιστώντας το αναμφισβήτητα την καλύτερη επιλογή για τη μοντελοποίηση της κατηγορίας MildDementia μεταξύ των αξιολογημένων συναρτήσεων ενεργοποίησης. Η στενή απόδοση της ELU την υποδηλώνει ως μια βιώσιμη εναλλακτική λύση, προσφέροντας στιβαρότητα δυνητικά κατάλληλη για παρόμοιες εργασίες. Η μειωμένη αποτελεσματικότητα της ReLU και της PReLU μπορεί να προέρχεται από τις εγγενείς ιδιότητές τους, όπως η τάση της ReLU να ακυρώνει τις αρνητικές ενεργοποιήσεις, οι οποίες θα μπορούσαν να είναι κρίσιμες για την αποτύπωση των λεπτοτήτων που είναι απαραίτητες για την αποτελεσματική διαφοροποίηση της κατηγορίας MildDementia.

Καμπύλες ROC & Επαναληψιμότητας – Ανάκλησης για τη κατηγορία ModerateDementia (Μέτρια Άνοια)

Η ReLU και η Leaky ReLU, δείχνουν σχεδόν πανομοιότυπες τροχιές και τις υψηλότερες τιμές AUC (βλ. *Εικ. 4.24.*). Αυτή η ομοιότητα υποδηλώνει ότι και οι δύο συναρτήσεις ενεργοποίησης διαθέτουν μια αξιόπαινη ικανότητα να διαφοροποιούν την κατηγορία ModerateDementia από άλλες κατηγορίες. Αντίθετα, η PReLU, υπολείπεται του σημείου αναφοράς της ReLU και της Leaky ReLU, σηματοδοτώντας μια μειωμένη ικανότητα διάκρισης στο ίδιο ταξικό πλαίσιο. Η ενεργοποίηση ELU, ενώ παρουσιάζει τη χαμηλότερη συνολική AUC, παρουσιάζει ενδιαφέροντα υψηλότερο Αληθώς Θετικό Ποσοστό σε χαμηλότερα Ψευδώς Θετικά Ποσοστά. Αυτό υποδηλώνει μια αρχική ευαισθησία στην κατηγορία ModerateDementia, η οποία, ωστόσο, μειώνεται καθώς το όριο για τη θετική ταξινόμηση γίνεται λιγότερο αυστηρό.

Η ανάλυση καμπύλης PR αναλύει περαιτέρω αυτή τη δυναμική. Η ELU ξεκινά με μια πολλά υποσχόμενη επαναληψιμότητα σε χαμηλότερα επίπεδα ανάκλησης, αλλά παρουσιάζει πτώση κάτω από τις αντίστοιχες καθώς επεκτείνεται η ανάκληση. Αυτό το μοτίβο υποδηλώνει ότι οι αρχικές προβλέψεις υψηλής εμπιστοσύνης της ELU για την κατηγορία ModerateDementia δεν μπορούν να διατηρηθούν σε ευρύτερη κάλυψη περιπτώσεων. Αντίθετα, η ReLU, αν και αρχικά υστερεί, σύντομα κλιμακώνεται σε υψηλά επίπεδα ακρίβειας, υπογραμμίζοντας την ικανότητά της να κάνει αξιόπιστες προβλέψεις πέρα από ένα συγκεκριμένο όριο. Οι Leaky ReLU και PReLU, εν τω μεταξύ, παρουσιάζουν σταθερά χαμηλότερη επαναληψιμότητα σε όλα τα επίπεδα ανάκλησης, με τη PReLU να είναι κυρίως η λιγότερο ακριβής.

Η σύνθεση αυτών των γνώσεων αποκαλύπτει το περίπλοκο τοπίο απόδοσης για την κατηγορία ModerateDementia. Το μικρό μέγεθος δείγματος που είναι εγγενές σε αυτήν την κλάση περιπλέκει την ερμηνεία της απόδοσης, συμβάλλοντας πιθανότατα στην παρατηρούμενη μεταβλητότητα στην AUC και την ακρίβεια στις συναρτήσεις ενεργοποίησης. Η ReLU και η Leaky ReLU αναδεικνύονται ως δυνητικά πιο ισχυρές επιλογές για αυτήν την πρόκληση ταξινόμησης, αντανακλώντας παρόμοιες και ανώτερες μετρήσεις απόδοσης. Η αρχική υψηλή ευαισθησία της ELU

μειώνεται στα επίπεδα ανάκλησης, υπονοώντας υπερπροσαρμογή σε περιορισμένες θετικές περιπτώσεις ή ανεπάρκεια αποτελεσματικής γενίκευσης. Η απόδοση της PReLU, που υστερεί και στις δύο αναλύσεις καμπύλης, μπορεί να υποδηλώνει την ανεπάρκειά της για περιβάλλοντα που χαρακτηρίζονται από ελάχιστη θετική αναπαράσταση κλάσης.

Καμπύλες ROC & Επαναληψιμότητας – Ανάκλησης για τη κατηγορία NonDementia (Χωρίς Άνοια)

Η ανάλυση καμπύλης ROC (βλ. *Εικ. 4.25*) τοποθετεί τη Leaky ReLU στην πρώτη γραμμή, επιδεικνύοντας την υψηλότερη AUC μεταξύ των αξιολογημένων λειτουργιών ενεργοποίησης, σηματοδοτώντας έτσι την ανώτερη αποτελεσματικότητά της στη διάκριση των περιπτώσεων NonDementia. Η ELU ακολουθεί πιστά, υποδεικνύοντας συγκρίσιμη επάρκεια σε αυτήν την εργασία ταξινόμησης, ενώ οι ReLU και PReLU παρουσιάζουν ελαφρώς χαμηλότερες τιμές AUC. Η PReLU, ειδικότερα, εμφανίζει τη χαμηλότερη AUC, υποδηλώνοντας μια σχετική έλλειψη στη διακριτική του δύναμη για την κατηγορία NonDementia.

Περαιτέρω εξερεύνηση μέσω της ανάλυσης καμπύλης PR ενισχύει την ηγετική θέση της Leaky ReLU, επιδεικνύοντας τη σταθερή της επαναληψιμότητα σε ένα ευρύ φάσμα επιπέδων ανάκλησης. Αυτή η συνέπεια υπογραμμίζει την ισχυρή ικανότητα της Leaky ReLU στον ακριβή εντοπισμό περιπτώσεων NonDementia. Η ELU διακρίνεται, ειδικά σε υψηλότερα επίπεδα ανάκλησης, όπου η επαναληψιμότητα της ξεπερνά αυτή της ReLU, υπογραμμίζοντας την αξιοπιστία της ELU στην καταγραφή μεγαλύτερου μέρους περιπτώσεων NonDementia. Από την άλλη πλευρά, η PReLU υστερεί στην επαναληψιμότητα σε χαμηλότερα επίπεδα ανάκλησης, αλλά βρίσκει σταθερότητα καθώς αυξάνεται η ανάκληση. Αυτό το μοτίβο μπορεί να υποδηλώνει τις προκλήσεις της PReLU με ακρίβεια όταν έχει αποστολή να εντοπίσει ένα μικρότερο υποσύνολο περιπτώσεων NonDementia.

Η Leaky ReLU αναδεικνύεται ως η πιο ισορροπημένη επιλογή, μεγιστοποιώντας επιδέξια την ανάκληση χωρίς συμβιβασμούς στην επαναληψιμότητα, καθιστώντας το μια εξαιρετική επιλογή για τον αποτελεσματικό εντοπισμό περιπτώσεων NonDementia. Η ELU αποδείχθηκε ιδιαίτερα πολύτιμη για σενάρια που ο εντοπισμός του ευρύτερου δυνατού φάσματος περιπτώσεων NonDementia είναι κρίσιμος. Η ReLU, αν και ικανή, δεν ταιριάζει απόλυτα με τα επίπεδα απόδοσης της Leaky ReLU ή της ELU σε διάφορα επίπεδα ανάκλησης. Η παρατηρούμενη απόδοση της PReLU υποδηλώνει πιθανές δυσκολίες στο χειρισμό κλάσεων με μεγαλύτερα μεγέθη δειγμάτων ή στην επίτευξη υψηλής επαναληψιμότητας σε όλο το φάσμα ανάκλησης, υποδεικνύοντας την ανάγκη για μια πιο διαφοροποιημένη προσέγγιση σε τέτοια περιβάλλοντα.

Καμπύλες ROC & Επαναληψιμότητας – Ανάκλησης για τη κατηγορία VeryMildDementia (Πολύ Ήπια Άνοια)

Η Leaky ReLU εμφανίζει την υψηλότερη AUC, υποδεικνύοντας την ανώτερη ικανότητά της να διακρίνει το στάδιο VeryMildDementia με ελάχιστα ψευδώς θετικά (βλ. *Εικ. 4.26*). Ωστόσο, καθώς αυξάνεται η ανοχή του μοντέλου για ψευδώς θετικά στοιχεία, η απόδοση της ELU, συγκλίνει και τελικά ξεπερνά αυτή της Leaky ReLU. Αυτό υποδηλώνει ότι η ELU μπορεί να προσφέρει καλύτερη απόδοση κάτω από πιο ήπιες ρυθμίσεις κατωφλίου. Η ReLU, αν και ξεκινά πολύ πίσω από την ELU, επιδεικνύει ανθεκτικότητα υπερτερώντας ελαφρώς της Leaky ReLU σε υψηλότερα ψευδώς θετικά ποσοστά. Αντίθετα, η PReLU δείχνει τη χαμηλότερη AUC,

υποδηλώνοντας μια συγκριτική ανεπάρκεια στη διαφοροποίηση του σταδίου VeryMildDementia καθώς το ψευδώς θετικό ποσοστό κλιμακώνεται.

Στην ανάλυση της καμπύλης PR, η Leaky ReLU ξεχωρίζει σε χαμηλότερα επίπεδα ανάκλησης, διατηρώντας υψηλή επαναληψιμότητα καθώς αρχίζει να καταγράφει πιο πραγματικές θετικές περιπτώσεις. Η ELU αντικατοπτρίζει πιστά αυτό το μοτίβο, ειδικά σε υψηλότερα επίπεδα ανάκλησης, υποδεικνύοντας την αποτελεσματικότητά της σε ένα ευρύτερο φάσμα ανάκλησης. Η ReLU, αν και αρχικά υστερεί, ξεπερνά τη PReLU περίπου σε ανάκληση 0,15 και παραμένει σε στενό ανταγωνισμό με τη Leaky ReLU και την ELU, υποδηλώνοντας αύξηση της αξιοπιστίας καθώς εντοπίζει μεγαλύτερο κλάσμα θετικών περιπτώσεων. Η PReLU, ωστόσο, παραμένει η λιγότερο αποτελεσματική στα περισσότερα επίπεδα ανάκλησης, υποδεικνύοντας πιθανές προκλήσεις για την επίτευξη ισορροπίας μεταξύ επαναληψιμότητας και ανάκλησης για την κατηγορία VeryMildDementia.

Η ισχυρή εμφάνιση της Leaky ReLU και στις δύο καμπύλες της VeryMildDementia υπογραμμίζει την ισορροπημένη προσέγγισή της στην ευαισθησία και την ειδικότητα, καθιστώντας το μια υποδειγματική επιλογή για αυτήν την εργασία ταξινόμησης. Η ELU αναδεικνύεται επίσης ως ισχυρή υποψήφια, με σταθερή απόδοση που υποδηλώνει την καταλληλότητά της ως αποτελεσματική συνάρτηση ενεργοποίησης για την κατηγορία VeryMildDementia. Η αξιοσημείωτη βελτίωση της απόδοσης της ReLU σε υψηλότερα επίπεδα ανάκλησης αντανακλά μια προσεκτική αλλά ολοένα και πιο σίγουρη προσέγγιση, υπονοώντας ένα δυνητικά συντηρητικό μοντέλο που αποκτά ακρίβεια καθώς διευρύνει τον εντοπισμό θετικών περιπτώσεων. Η υποαπόδοση της PReLU και στις δύο μετρήσεις μπορεί να σηματοδοτεί υποκείμενα ζητήματα με την αναπαράσταση χαρακτηριστικών ή τη ρύθμιση ορίου, υποδεικνύοντας περιοχές που θα μπορούσαν να ωφεληθούν από περαιτέρω βελτιστοποίηση μοντέλου ή προσαρμογές προεπεξεργασίας δεδομένων.

5.6. Συμπέρασμα

Η ανάλυση των μετρήσεων απόδοσης σε διαφορετικές συναρτήσεις ενεργοποίησης, ReLU, Leaky ReLU, PReLU και ELU, παρέχει οξυδερκή συμπεράσματα σχετικά με την αποτελεσματικότητά τους στην ταξινόμηση των διαφόρων σταδίων άνοιας, τονίζοντας διακριτά πλεονεκτήματα και περιορισμούς. Η PReLU διακρίνεται με μια εντυπωσιακή έναρξη μάθησης, όπως αποδεικνύεται από μια ταχεία αύξηση της AUC και μια ταχεία μείωση της απώλειας. Αυτή η πρόωμη δυναμική, ωστόσο, σύντομα φτάνει σε ένα πλάτωμα, εγείροντας ανησυχίες για πιθανή υπερπροσαρμογή λόγω της πρόωμης σύγκλισης. Η ELU, αντίθετα, επιδεικνύει την ικανότητα γρήγορης μάθησης, διατηρώντας παράλληλα τη βελτίωση για μεγαλύτερο χρονικό διάστημα, υποδηλώνοντας μια ανώτερη ικανότητα γενίκευσης χωρίς να φτάσει σε ένα πρόωμο ανώτατο όριο απόδοσης. Η Leaky ReLU παρουσιάζει μια σταθερή πρόοδο στη μάθηση, αντικατοπτρίζοντας μια πιο σταδιακή αλλά σταθερή απορρόφηση πληροφοριών που θα μπορούσε να συμβάλει στη μακροπρόθεσμη ευρωστία του μοντέλου. Η καμπύλη μάθησης της ReLU, που χαρακτηρίζεται από μια σταδιακή κλίση, σηματοδοτεί τον πιο αργό ρυθμό αρχικής μάθησης, αλλά δείχνει μια συνεχή δυνατότητα βελτίωσης με παρατεταμένη εκπαίδευση.

Οι επιδόσεις για συγκεκριμένη κατηγορία οριοθετούν περαιτέρω τα δυνατά σημεία κάθε συνάρτησης ενεργοποίησης:

- Για την MildDementia, η Leaky ReLU αναδεικνύεται ως η πιο αποτελεσματική, επιτυγχάνοντας την υψηλότερη AUC και διατηρώντας την επαναληψιμότητα σε διάφορα επίπεδα ανάκλησης.

- Για την αντιμετώπιση της ModerateDementia, τόσο η ReLU όσο και η Leaky ReLU εμφανίζουν αξιόπαινη απόδοση, αν και η ELU δείχνει μεγαλύτερη αρχική ευαισθησία. Η πρόκληση σε αυτήν την κατηγορία έγκειται κυρίως στο περιορισμένο μέγεθος δείγματος, που περιπλέκει την ακριβή αξιολόγηση της απόδοσης.
- Η Leaky ReLU ηγείται και πάλι στην ταξινόμηση των δεδομένων της NonDementia, επιδεικνύοντας την ικανότητά της με την υψηλότερη επαναληψιμότητα και AUC. Η ισχύς της ELU σε υψηλότερα επίπεδα ανάκλησης υποδηλώνει επίσης την αποτελεσματικότητά της στη διασφάλιση ολοκληρωμένης αναγνώρισης περιπτώσεων NonDementia.
- Με την VeryMildDementia, η ισορροπημένη προσέγγιση της Leaky ReLU αποδίδει υψηλή AUC, ειδικά σε χαμηλότερα επίπεδα ανάκλησης, ενώ η ELU γίνεται ισχυρός υποψήφιος καθώς αυξάνεται η ανάκληση, υποδεικνύοντας τη χρησιμότητά της σε συγκεκριμένα σενάρια.

Συναρτήσεις γρήγορης εκμάθησης όπως η PReLU και η ELU είναι πλεονεκτικές για την πρώιμη αξιολόγηση και επανάληψη του μοντέλου. Ωστόσο, για μεγαλύτερη διάρκεια εκπαίδευσης ή όταν είναι στόχος η γενικευμένη εφαρμογή μοντέλου, προτιμώνται οι δυνατότητες συνεχούς μάθησης της ReLU και της Leaky ReLU. Η ταχεία πρόοδος της PReLU και η επακόλουθη κατάρρευση απαιτούν την εξέταση υπερβολικών αντιμέτρων, όπως η τακτοποίηση. Εν τω μεταξύ, η σταθερή απόδοση της ELU χωρίς μείωση της AUC δείχνει την στιβαρότητά της και τις δυνατότητες περαιτέρω βελτίωσης με πρόσθετη εκπαίδευση.

Συμπερασματικά, η Leaky ReLU ξεχωρίζει για τη σταθερή του αποτελεσματικότητα σε διαφορετικά στάδια και μετρήσεις άνοιας, παρουσιάζοντας τον εαυτό της ως μια καθολικά εφαρμόσιμη επιλογή για το σύνολο δεδομένων. Η ELU προσφέρει επίσης σημαντική αξία, ιδιαίτερα για μοντέλα που υποβάλλονται σε εκτεταμένες περιόδους εκπαίδευσης, επιδεικνύοντας την ευρεία εφαρμογή της. Η επιλογή μεταξύ αυτών των συναρτήσεων ενεργοποίησης θα πρέπει να προσαρμόζεται στις συγκεκριμένες ανάγκες της εργασίας, λαμβάνοντας υπόψη παράγοντες όπως η διάρκεια της εκπαίδευσης, οι προτεραιότητες ταχείας ανάπτυξης και η πρόκληση της ανισορροπίας της τάξης.

5.7. Συγκριτική Ανάλυση με Άλλες Μελέτες

Μετά την οριστικοποίηση του μοντέλου και την επιλογή των κατάλληλων συναρτήσεων ενεργοποίησης, είναι σημαντικό να συγκριθεί η αποτελεσματικότητα του σε σχέση με τις υπάρχουσες προσπάθειες ταξινόμησης εικόνων σε ανάλογα σύνολα δεδομένων. Αυτή η αξιολόγηση βασίζεται σε μια ανασκόπηση που πραγματοποιήθηκε μέσω του Kaggle, εστιάζοντας στις προκλήσεις ταξινόμησης εικόνων MRI και στα αποτελέσματά τους. Μια τέτοια σύγκριση προσφέρει μια ολιστική άποψη της απόδοσης του κώδικα, ενώ διευκολύνει επίσης τις συζητήσεις σχετικά με τη δυνατότητα εφαρμογής του σε πρόσθετα σύνολα δεδομένων.

Συγκεκριμένα, οι Bombassei et al. (2022) [110] υιοθέτησαν μια εναλλακτική προσέγγιση τμηματοποίησης δεδομένων, κατηγοριοποιώντας 6400 εικόνες MRI από 200 άτομα σε αντίστοιχα σύνολα εκπαίδευσης και ελέγχου με βάση το θέμα και την κλάση, διαθέτοντας το 80% για την εκπαίδευση – επικύρωση και το 20% για τον έλεγχο. Αυτή η στρατηγική, βασισμένη στην υπόθεση της συσχέτισης εικόνας εντός του θέματος, στόχευε να μειώσει τα σφάλματα ταξινόμησης. Ωστόσο, αυτή η προσέγγιση απέτυχε να ταξινομήσει με ακρίβεια την κατηγορία ModerateDementia και MildDementia, αποδίδοντας μέτρια ακρίβεια 55%. Μια επακόλουθη στρατηγική από την ίδια ομάδα, που περιελάμβανε συγχώνευση δεδομένων και ανακατασκευή

δεδομένων, επαυξημένη με προσαρμογές βάρους κατηγορίας για τον μετριάσμο της ανισορροπίας κατηγορίας, βελτίωσε σημαντικά την απόδοση του μοντέλου, επιτυγχάνοντας ακρίβεια 97% και ολοκληρωμένη ταξινόμηση, ξεπερνώντας αισθητά τη μέγιστη ακρίβεια του μοντέλου μας, σχεδόν 70%.

Σε μια ξεχωριστή μελέτη, οι Subramanian et al. (2021) [111] χρησιμοποίησαν τεχνικές υπερδειγματοληψίας και αύξησης δεδομένων, συμπεριλαμβανομένου του ζουμ εικόνας, της αναστροφής και της αυξομείωσης κλίμακας φωτεινότητας, παράλληλα με τη χρήση του προεκπαιδευμένου μοντέλου Inception v3. Αυτή η πολύπλευρη προσέγγιση ενίσχυσε το σύνολο δεδομένων σε 12800 εικόνες, βελτιώνοντας ουσιαστικά την ακρίβεια ταξινόμησης σε περίπου 95%, αποδεικνύοντας έτσι τις ισχυρές δυνατότητες ταξινόμησης του μοντέλου σε διαφορετικές κατηγορίες.

Έχοντας λοιπόν κάνει ανασκόπηση αυτών των εργασιών, μπορούμε να συμπεράνουμε πως η χρήση ενός πιο ισορροπημένου συνόλου δεδομένων για την εκπαίδευση του μοντέλου μπορεί να φέρει πολύ καλύτερα αποτελέσματα, αλλά και η χρήση τεχνικών αύξησης δεδομένων ή προεκπαιδευμένων μοντέλων μπορεί να ενισχύσει σημαντικά την απόδοση, σκεπτόμενοι φυσικά την υπολογιστική ισχύ.

5.8. Ευρύτερη Δυνατότητα Βαθιάς Μάθησης στην Ιατρική Απεικόνιση

Η ανάλυσή μας ρίχνει φως στην περίπλοκη σχέση μεταξύ των συναρτήσεων ενεργοποίησης και της επιρροής τους στην απόδοση του μοντέλου εντός του εξειδικευμένου τομέα της ταξινόμησης εικόνων για την AD. Εμβαθύνοντας στη σφαίρα του ρόλου της βαθιάς μάθησης στην ιατρική απεικόνιση, αποκαλύπτονται οι πρωτοποριακές δυνατότητές της σε μια σειρά ασθενειών και διαγνωστικών μεθόδων. Τα ποικίλα χαρακτηριστικά απόδοσης των συναρτήσεων ενεργοποίησης, που κυμαίνονται από το γρήγορο ξεκίνημα της PReLU στη μάθηση έως τις ανώτερες δυνατότητες γενίκευσης της ELU, τονίζουν τον κρίσιμο ρόλο που διαδραματίζουν οι αρχιτεκτονικές επιλογές στη βαθιά μάθηση στην ανάπτυξη μοντέλων που είναι ακριβώς προσαρμοσμένα στις συγκεκριμένες προκλήσεις της ιατρικής απεικόνισης.

Αυτή η προσαρμοστικότητα και η αποτελεσματικότητα υποδηλώνουν ένα πολλά υποσχόμενο μέλλον όπου τα προσεκτικά σχεδιασμένα μοντέλα βαθιάς μάθησης θα μπορούσαν να βελτιώσουν σημαντικά την ακρίβεια, την ταχύτητα και την αποτελεσματικότητα των διαγνωστικών διαδικασιών σε ένα ευρύ φάσμα επιστημονικών κλάδων ιατρικής απεικόνισης. Συγκεκριμένα, η βαθιά μάθηση έχει τη δυνατότητα να επαναπροσδιορίσει την ανίχνευση και την ταξινόμηση του καρκίνου, προσφέροντας προηγμένη ακρίβεια στον εντοπισμό καρκινικών βλαβών σε διαφορετικές τεχνικές απεικόνισης, όπως αξονικές τομογραφίες, μαστογραφία και σαρώσεις PET. Αυτή η πρόοδος είναι μεγάλης σημασίας για την έγκαιρη διάγνωση και τη δημιουργία σχεδίων θεραπείας, όπως αποδεικνύεται από έρευνες όπως αυτή των Nasser et al. (2023) [112], το οποίο υπογραμμίζει τον αντίκτυπο της βαθιάς μάθησης στη διάγνωση του καρκίνου του μαστού.

Στην καρδιαγγειακή απεικόνιση, η βαθιά μάθηση είναι έτοιμη να φέρει επανάσταση στην ανάλυση των υπερηχοκαρδιογραφημάτων, μαγνητικής τομογραφίας και αξονικής τομογραφίας, ενισχύοντας την ανίχνευση καρδιακών παθήσεων και προσφέροντας πλουσιότερες γνώσεις για την καρδιακή και αγγειακή υγεία. Αν και περιμένουμε μια ολοκληρωμένη ανασκόπηση του ρόλου της τεχνητής νοημοσύνης στην καρδιαγγειακή απεικόνιση [113], η υπάρχουσα επιτυχία της βαθιάς μάθησης σε διάφορους τομείς ιατρικής απεικόνισης υποδηλώνει τη δυνατότητά της

να βελτιώσει σημαντικά την καρδιακή απεικόνιση μέσω της αυτόματης εξαγωγής χαρακτηριστικών και της διαγνωστικής ακρίβειας.

Επιπλέον, η χρησιμότητα της βαθιάς μάθησης εκτείνεται πέρα από τη AD για να περιλαμβάνει την ανίχνευση και ταξινόμηση άλλων νευρολογικών διαταραχών, όπως η νόσος του Πάρκινσον, η σκλήρυνση κατά πλάκας και οι όγκοι του εγκεφάλου. Χρησιμοποιώντας μαγνητική τομογραφία και αξονική τομογραφία, η βαθιά μάθηση μπορεί να παρέχει λεπτομερείς αξιολογήσεις της υγείας του εγκεφάλου, όπως τονίζεται από τους Jo et al. (2019) [114] στην εξερεύνηση του αντίκτυπου της βαθιάς μάθησης στα διαγνωστικά του Αλτσχάιμερ.

Στην ορθοπαιδική, η εφαρμογή της βαθιάς μάθησης υπόσχεται να προωθήσει τη διάγνωση και την παρακολούθηση καταστάσεων όπως κατάγματα, μυοσκελετικές κακώσεις και εκφυλιστικές ασθένειες μέσω βελτιωμένης ανάλυσης εικόνας ακτινογραφιών, αξονικών τομογράφων και εικόνων MRI. Η δυνατότητα βαθιάς μάθησης για τη μετατροπή της ορθοπαιδικής απεικόνισης, που προκύπτει από την αποτελεσματικότητά της σε άλλους τομείς όπως η ανίχνευση καρκίνου του μαστού και του δέρματος, υποδηλώνει ένα μέλλον βελτιωμένης διαγνωστικής ακρίβειας και αυτοματοποιημένων αξιολογήσεων.

Η βαθιά εκμάθηση στοχεύει επίσης να φέρει επανάσταση στην κατάτμηση οργάνων και ιστών στις ιατρικές εικόνες, διευκολύνοντας την τρισδιάστατη ανακατασκευή για εξατομικευμένες ιατρικές παρεμβάσεις, όπως αναλύεται από τους Chen et al. (2022) [115]. Οι εξελίξεις σε αυτόν τον τομέα αντικατοπτρίζουν τη συνολική επιτυχία των μοντέλων βαθιάς μάθησης στον εμπλουτισμό της ανάλυσης εικόνας σε διάφορους ιατρικούς κλάδους.

Η αποτελεσματική εφαρμογή διαφορετικών συναρτήσεων ενεργοποίησης στο μοντέλο ταξινόμησης της AD υπογραμμίζει την κρίσιμη σημασία της προσεκτικής επιλογής τεχνικών βαθιάς μάθησης που ανταποκρίνονται στις συγκεκριμένες ανάγκες κάθε εργασίας ιατρικής απεικόνισης. Αυτή η ευελιξία, μαζί με τη συνεχή πρόοδο στην υπολογιστική ισχύ και την αλγοριθμική καινοτομία, ενισχύει τον ρόλο της βαθιάς μάθησης ως ακρογωνιαίο λίθο στην εξέλιξη της τεχνολογίας ιατρικής απεικόνισης.

Αξιοποιώντας τη δύναμη της βαθιάς μάθησης, ο ιατρικός τομέας βρίσκεται στο χείλος της εισόδου σε μια νέα εποχή διαγνωστικής απεικόνισης, όπου σύνθετες ασθένειες εντοπίζονται με πρωτοφανή ακρίβεια και ταχύτητα. Αυτή η αλλαγή πρόκειται να βελτιώσει σημαντικά τα αποτελέσματα των ασθενών και να οδηγήσει την πρόοδο της εξατομικευμένης ιατρικής, εγκαινιάζοντας μια περίοδο καινοτομίας και βελτιωμένης παροχής υγειονομικής περίθαλψης.

Βιβλιογραφία

1. World Health Organization. (2023, March 15). *Dementia*. Who.int; World Health Organization: WHO. <https://www.who.int/en/news-room/fact-sheets/detail/dementia>
2. Dementia & amnestic disorders. Simon R.P., & Aminoff M.J., & Greenberg D.A.(Eds.), [publicationyear2] *Clinical Neurology, 10e*. McGraw-Hill Education. <https://accessmedicine.mhmedical.com/content.aspx?bookid=2274§ionid=176232284>
3. Knopman, D. S., Amieva, H., Petersen, R. C., Chételet, G., Holtzman, D. M., Hyman, B. T., Nixon, R. A., & Jones, D. T. (2021). Alzheimer disease. *Nature Reviews Disease Primers*, 7(1). <https://doi.org/10.1038/s41572-021-00269-y>
4. Querfurth, H. W., & LaFerla, F. M. (2010). Alzheimer's Disease. *New England Journal of Medicine*, 362(4), 329–344. <https://doi.org/10.1056/nejmra0909142>
5. Todd, S., Barr, S., Roberts, M., & Passmore, A. P. (2013). Survival in dementia and predictors of mortality: a review. *International Journal of Geriatric Psychiatry*, 28(11), 1109–1124. <https://doi.org/10.1002/gps.3946>
6. Burns, A., & Iliffe, S. (2009). Alzheimer's disease. *BMJ*, 338(feb05 1), b158–b158. <https://doi.org/10.1136/bmj.b158>
7. Long, J. M., & Holtzman, D. M. (2019). Alzheimer Disease: An Update on Pathobiology and Treatment Strategies. *Cell*, 179(2), 312–339. <https://doi.org/10.1016/j.cell.2019.09.001>
8. “Study reveals how APOE4 gene may increase risk for dementia”. (2021, March 16). National Institute on Aging. <https://www.nia.nih.gov/news/study-reveals-how-apoe4-gene-may-increase-risk-dementia>
9. Ramos-Cejudo, J., Wisniewski, T., Marmar, C., Zetterberg, H., Blennow, K., de Leon, M. J., & Fossati, S. (2018). Traumatic Brain Injury and Alzheimer's Disease: *The Cerebrovascular Link. EBioMedicine*, 28, 21–30. <https://doi.org/10.1016/j.ebiom.2018.01.021>
10. Tahami Monfared, A. A., Byrnes, M. J., White, L. A., & Zhang, Q. (2022). Alzheimer's Disease: Epidemiology and Clinical Progression. *Neurology and therapy*, 11(2), 553–569. <https://doi.org/10.1007/s40120-022-00338-8>
11. Fiest, K. M., Roberts, J. I., Maxwell, C. J., Hogan, D. B., Smith, E. E., Frolkis, A., Cohen, A., Kirk, A., Pearson, D., Pringsheim, T., Venegas-Torres, A., & Jetté, N. (2016). The Prevalence and Incidence of Dementia Due to Alzheimer's Disease: a Systematic Review and Meta-Analysis. *The Canadian journal of neurological sciences. Le journal canadien des sciences neurologiques*, 43 Suppl 1, S51–S82. <https://doi.org/10.1017/cjn.2016.36>
12. Takizawa, C., Thompson, P. L., van Walsem, A., Faure, C., & Maier, W. C. (2015). Epidemiological and economic burden of Alzheimer's disease: a systematic literature review of data across Europe and the United States of America. *Journal of Alzheimer's disease : JAD*, 43(4), 1271–1284. <https://doi.org/10.3233/JAD-141134>
13. Niu, H., Álvarez-Álvarez, I., Guillén-Grima, F., & Aguinaga-Ontoso, I. (2017). Prevalence and incidence of Alzheimer's disease in Europe: A meta-analysis. Prevalencia e incidencia de la enfermedad de Alzheimer en Europa: metaanálisis. *Neurologia (Barcelona, Spain)*, 32(8), 523–532. <https://doi.org/10.1016/j.nrl.2016.02.016>
14. Cui, L., Hou, N. N., Wu, H. M., Zuo, X., Lian, Y. Z., Zhang, C. N., Wang, Z. F., Zhang, X., & Zhu, J. H. (2020). Prevalence of Alzheimer's Disease and Parkinson's Disease in China: An Updated Systematical Analysis. *Frontiers in aging neuroscience*, 12, 603854. <https://doi.org/10.3389/fnagi.2020.603854>
15. Chan, K. Y., Wang, W., Wu, J. J., Liu, L., Theodoratou, E., Car, J., Middleton, L., Russ, T. C., Deary, I. J., Campbell, H., Wang, W., Rudan, I., & Global Health Epidemiology Reference Group (GHERG) (2013). Epidemiology of Alzheimer's disease and other forms of dementia in China, 1990-2010: a systematic review and analysis. *Lancet (London, England)*, 381(9882), 2016–2023. [https://doi.org/10.1016/S0140-6736\(13\)60221-4](https://doi.org/10.1016/S0140-6736(13)60221-4)
16. Zhao, X., & Li, X. (2020). The prevalence of Alzheimer's disease in the Chinese Han population: a meta-analysis. *Neurological research*, 42(4), 291–298. <https://doi.org/10.1080/01616412.2020.1716467>
17. Brookmeyer, R., Abdalla, N., Kawas, C. H., & Corrada, M. M. (2018). Forecasting the prevalence of preclinical and clinical Alzheimer's disease in the United States. *Alzheimer's & dementia : the journal of the Alzheimer's Association*, 14(2), 121–129. <https://doi.org/10.1016/j.jalz.2017.10.009>
18. NHS . (2021, July 5). *Symptoms - Alzheimer's disease*. NHS. <https://www.nhs.uk/conditions/alzheimers-disease/symptoms/>
19. National Institute on Aging. (2023, April 5). *Alzheimer's Disease Fact Sheet*. National Institute on Aging. <https://www.nia.nih.gov/health/alzheimers-and-dementia/alzheimers-disease-fact-sheet>

20. Dearing, W. J., & Grossberg, G. T. (2019). Behavioral and psychological symptoms in Alzheimer's dementia and vascular dementia. *Handbook of clinical neurology*, 165, 5–32. <https://doi.org/10.1016/B978-0-444-64012-3.00002-2>
21. Murray, E. D., Büttner, E., & Price, B. H. (2012). Depression and Psychosis in Neurological Practice. *Elsevier EBooks*, 92–116. <https://doi.org/10.1016/b978-1-4377-0434-1.00009-8>
22. Dearing, W. J., & Grossberg, G. T. (2019). Behavioral and psychological symptoms in Alzheimer's dementia and vascular dementia. *Handbook of clinical neurology*, 165, 5–32. <https://doi.org/10.1016/B978-0-444-64012-3.00002-2>
23. Petersen, R. C., Lopez, O., Armstrong, M. J., Getchius, T. S. D., Ganguli, M., Gloss, D., Gronseth, G. S., Marson, D., Pringsheim, T., Day, G. S., Sager, M., Stevens, J., & Rae-Grant, A. (2018). Practice guideline update summary: Mild cognitive impairment: Report of the Guideline Development, Dissemination, and Implementation Subcommittee of the American Academy of Neurology. *Neurology*, 90(3), 126–135. <https://doi.org/10.1212/WNL.0000000000004826>
24. Carlesimo, G. A., & Oscar-Berman, M. (1992). Memory deficits in Alzheimer's patients: a comprehensive review. *Neuropsychology review*, 3(2), 119–169. <https://doi.org/10.1007/BF01108841>
25. Benke, T., Andree, B., Hittmair, M., & Gerstenbrand, F. (1990). [Speech changes in dementia]. *Fortschritte Der Neurologie-Psychiatrie*, 58(6), 215–223. <https://doi.org/10.1055/s-2007-1001185>
26. Förstl, H., & Kurz, A. (1999). Clinical features of Alzheimer's disease. *European archives of psychiatry and clinical neuroscience*, 249(6), 288–290. <https://doi.org/10.1007/s004060050101>
27. Volicer, L., Harper, D. G., Manning, B. C., Goldstein, R., & Satlin, A. (2001). Sundowning and circadian rhythms in Alzheimer's disease. *The American journal of psychiatry*, 158(5), 704–711. <https://doi.org/10.1176/appi.ajp.158.5.704>
28. Mashour, G. A., Frank, L., Batthyany, A., Kolanowski, A. M., Nahm, M., Schulman-Green, D., Greyson, B., Pakhomov, S., Karlawish, J., & Shah, R. C. (2019). Paradoxical lucidity: A potential paradigm shift for the neurobiology and treatment of severe dementias. *Alzheimer's & dementia: the journal of the Alzheimer's Association*, 15(8), 1107–1114. <https://doi.org/10.1016/j.jalz.2019.04.002>
29. Planche, V., Manjon, J. V., Mansencal, B., Lanuza, E., Tourdias, T., Catheline, G., & Coupé, P. (2022). Structural progression of Alzheimer's disease over decades: the MRI staging scheme. *Brain Communications*, 4(3). <https://doi.org/10.1093/braincomms/fcac109>
30. Tabatabaei-Jafari, H., Walsh, E., Shaw, M. E., & Cherbuin, N. (2017). The cerebellum shrinks faster than normal ageing in Alzheimer's disease but not in mild cognitive impairment. *Human Brain Mapping*, 38(6), 3141–3150. <https://doi.org/10.1002/hbm.23580>
31. Tombaugh, T. N., & McIntyre, N. J. (1992). The mini-mental state examination: a comprehensive review. *Journal of the American Geriatrics Society*, 40(9), 922–935. <https://doi.org/10.1111/j.1532-5415.1992.tb01992.x>
32. Freitas, S., Simões, M. R., Alves, L., & Santana, I. (2013). Montreal Cognitive Assessment: Validation Study for Mild Cognitive Impairment and Alzheimer Disease. *Alzheimer Disease & Associated Disorders*, 27(1), 37–43. <https://doi.org/10.1097/wad.0b013e3182420bfe>
33. Blennow, K., Hampel, H., Weiner, M., & Zetterberg, H. (2010). Cerebrospinal fluid and plasma biomarkers in Alzheimer disease. *Nature Reviews. Neurology*, 6(3), 131–144. <https://doi.org/10.1038/nrneurol.2010.4>
34. Berger, A. (2002). How does it work?: Magnetic resonance imaging. *BMJ*, 324(7328), 35–35. <https://doi.org/10.1136/bmj.324.7328.35>
35. Simmons, A., Westman, E., Muehlboeck, S., Mecocci, P., Vellas, B., Tsolaki, M., Kłoszewska, I., Wahlund, L.-O., Soininen, H., Lovestone, S., Evans, A., & Spenger, C. (2009). MRI Measures of Alzheimer's Disease and the AddNeuroMed Study. *Annals of the New York Academy of Sciences*, 1180(1), 47–55. <https://doi.org/10.1111/j.1749-6632.2009.05063.x>
36. Berger A. (2003). How does it work? Positron emission tomography. *BMJ (Clinical research ed.)*, 326(7404), 1449. <https://doi.org/10.1136/bmj.326.7404.1449>
37. Marcus, C., Mena, E., & Subramaniam, R. M. (2014). Brain PET in the Diagnosis of Alzheimer's Disease. *Clinical Nuclear Medicine*, 39(10), e413–e426. <https://doi.org/10.1097/rnu.0000000000000547>
38. Chandra, A., Dervenoulas, G., Politis, M., & Alzheimer's Disease Neuroimaging Initiative. (2019). Magnetic resonance imaging in Alzheimer's disease and mild cognitive impairment. *Journal of Neurology*, 266(6), 1293–1302. <https://doi.org/10.1007/s00415-018-9016-3>

39. Luciano, Nitrini, R., Andrea Parolin Jackowski, & Francisco, O. (2009). *Diffusion tensor imaging for Alzheimer's disease: A review of concepts and potential clinical applicability*. 3(4), 268–274. <https://doi.org/10.1590/s1980-57642009dn30400002>
40. Alsop, D. C., Dai, W., Grossman, M., & Detre, J. A. (2010). Arterial Spin Labeling Blood Flow MRI: Its Role in the Early Characterization of Alzheimer's Disease. *Journal of Alzheimer's Disease*, 20(3), 871–880. <https://doi.org/10.3233/jad-2010-091699>
41. Mandal, P. K. (2007). Magnetic resonance spectroscopy (MRS) and its application in Alzheimer's disease. *Concepts in Magnetic Resonance Part A*, 30A(1), 40–64. <https://doi.org/10.1002/cmr.a.20072>
42. Gore, J. C. (2003). Principles and practice of functional MRI of the human brain. *Journal of Clinical Investigation*, 112(1), 4–9. <https://doi.org/10.1172/jci19010>
43. Ker, J., Wang, L., Rao, J., & Lim, T. (2018). Deep Learning Applications in Medical Image Analysis. *IEEE Access*, 6, 9375–9389. <https://doi.org/10.1109/ACCESS.2017.2788044>
44. LeCun, Y., Bengio, Y., & Hinton, G. (2015). Deep Learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
45. Zakaria, M., Al-Shebany, M., & Sarhan, S. (2014). Artificial Neural Network : A Brief Overview. *Journal of Engineering Research and Applications* www.ijera.com, 4(2), 7–12. https://www.ijera.com/papers/Vol4_issue2/Version%201/B42010712.pdf
46. *Artificial Neural Network - an overview | ScienceDirect Topics*. (n.d.). www.sciencedirect.com. <https://www.sciencedirect.com/topics/computer-science/artificial-neural-network>
47. W. Samek, G. Montavon, S. Lapuschkin, C. J. Anders and K. -R. Müller, "Explaining Deep Neural Networks and Beyond: A Review of Methods and Applications," in *Proceedings of the IEEE*, vol. 109, no. 3, pp. 247-278, March 2021, doi: 10.1109/JPROC.2021.3060483.
48. Sarker, I. H. (2021). Deep Learning: A Comprehensive Overview on Techniques, Taxonomy, Applications and Research Directions. *SN Computer Science*, 2(6). Springer. <https://doi.org/10.1007/s42979-021-00815-1>
49. Abirami, S., & Chitra, P. (2020). *Multilayer Perceptron - an overview | ScienceDirect Topics*. www.sciencedirect.com. <https://www.sciencedirect.com/topics/computer-science/multilayer-perceptron>
50. *Building a Regression Multi-Layer Perceptron (MLP)*. (n.d.). [Kaggle.com](http://kaggle.com). Retrieved January 3, 2024, from <https://www.kaggle.com/code/mejbahahammad/building-a-regression-multi-layer-perceptron-mlp?scriptVersionId=41676981&cellId=1>
51. Shun-ichi Amari (1993). *Backpropagation and stochastic gradient descent method.* , 5(4-5), 185–196. doi:10.1016/0925-2312(93)90006-o
52. Xue, Y., Tong, Y., & Neri, F. (2022). An ensemble of differential evolution and Adam for training feed-forward neural networks. *Information Sciences*, 608, 453–471. <https://doi.org/10.1016/j.ins.2022.06.036>
53. Singhal, A., & Devendra Kumar Sharma. (2023). Voice signal-based disease diagnosis using IoT and learning algorithms for healthcare. *Elsevier EBooks*, 59–81. <https://doi.org/10.1016/b978-0-323-91916-6.00005-9>
54. Noh, J., Trevon Badloe, Lee, C., Yun, J., So, S., & Rho, J. (2023). Inverse design meets nanophotonics: From computational optimization to artificial neural network. *Elsevier EBooks*, 3–32. <https://doi.org/10.1016/b978-0-323-85796-3.00001-9>
55. Kang, N. (2017, June 27). *Multi-Layer Neural Networks with Sigmoid Function— Deep Learning for Rookies (2)*. Towards Data Science; Towards Data Science. <https://towardsdatascience.com/multi-layer-neural-networks-with-sigmoid-function-deep-learning-for-rookies-2-bf464f09eb7f>
56. Kumaraswamy, B. (2021). Neural networks for data classification. *Artificial Intelligence in Data Mining*, 109–131. <https://doi.org/10.1016/b978-0-12-820601-0.00011-2>
57. DiPietro, R., & Hager, G. D. (2020). Deep learning: RNNs and LSTM. *Handbook of Medical Image Computing and Computer Assisted Intervention*, 503–519. <https://doi.org/10.1016/b978-0-12-816176-0.00026-0>
58. Yu, Y., Si, X., Hu, C., & Zhang, J. (2019). A Review of Recurrent Neural Networks: LSTM Cells and Network Architectures. *Neural Computation*, 31(7), 1235–1270. https://doi.org/10.1162/neco_a_01199
59. Sakib, S., Ahmed, N., Kabir, A. J., & Ahmed, H. (2019). An Overview of Convolutional Neural Network: Its Architecture and Applications. www.preprints.org. <https://doi.org/10.20944/preprints201811.0546.v4>
60. Wani, M. A., Bhat, F. A., Afzal, S., & Khan, A. I. (2019). Basics of Supervised Deep Learning. *Studies in Big Data*, 13–29. https://doi.org/10.1007/978-981-13-6794-6_2

61. Teuwen, J., & Moriakov, N. (2020). Convolutional neural networks. *Handbook of Medical Image Computing and Computer Assisted Intervention*, 481–501. <https://doi.org/10.1016/b978-0-12-816176-0.00025-9>
62. Ratan, P. (2020, October 28). *Convolutional Neural Network Made Easy for Data Scientists*. Analytics Vidhya. <https://www.analyticsvidhya.com/blog/2020/10/what-is-the-convolutional-neural-network-architecture/>
63. dshahid380. (2019, February 24). *Convolutional Neural Network*. Medium; Towards Data Science. <https://towardsdatascience.com/covolutional-neural-network-cb0883dd6529>
64. *Convolutional Neural Networks: 1998-2023 Overview | SuperAnnotate*. (n.d.). www.superannotate.com. <https://www.superannotate.com/blog/guide-to-convolutional-neural-networks>
65. Wang, R. (2016). Edge Detection Using Convolutional Neural Network. *Advances in Neural Networks – ISNN 2016*, 12–20. https://doi.org/10.1007/978-3-319-40663-3_2
66. Hassan, Hassan & Goussev, Serguei. (2019). Deep learning approach to automatic detection of faults and fractures from magnetic data using the convolutional neural network (CNN).
67. Senol, C. (2020, April 17). *Convolution Operation with GIMP — Edge Detection CNN*. Medium. <https://medium.com/@cihan.senol06/convolution-operation-with-gimp-edge-detection-cnn-f61144c4684a>
68. Gu, J., Wang, Z., Kuen, J., Ma, L., Shahroudy, A., Shuai, B., Liu, T., Wang, X., Wang, G., Cai, J., & Chen, T. (2018). Recent advances in convolutional neural networks. *Pattern Recognition*, 77, 354–377. <https://doi.org/10.1016/j.patcog.2017.10.013>
69. Ali, M. (2023, November 9). *Introduction to activation functions in neural networks*. DataCamp. <https://www.datacamp.com/tutorial/introduction-to-activation-functions-in-neural-networks>
70. Huang, W., Xue, Y., & Wu, Y. (2019). A CAD system for pulmonary nodule prediction based on deep three-dimensional convolutional neural networks and ensemble learning. *PLOS ONE*, 14(7), e0219369. <https://doi.org/10.1371/journal.pone.0219369>
71. Lin, G., & Shen, W. (2018). Research on convolutional neural network based on improved Relu piecewise activation function. *Procedia Computer Science*, 131, 977–984. <https://doi.org/10.1016/j.procs.2018.04.239>
72. Liang, X., & Xu, J. (2020). Biased ReLU Neural Networks. *Neurocomputing*. <https://doi.org/10.1016/j.neucom.2020.09.050>
73. Li, Z. & Nash, W. & Brien, S. & Qiu, Y. & Gupta, Rajeev & Birbilis, Nick. (2022). *cardiGAN: A Generative Adversarial Network Model for Design and Discovery of Multi Principal Element Alloys*
74. Yang, D., Ngoc, K. M., Shin, I., & Hwang, M. (2023). DPReLU: Dynamic Parametric Rectified Linear Unit and Its Proper Weight Initialization Method. *International Journal of Computational Intelligence Systems*, 16(1). <https://doi.org/10.1007/s44196-023-00186-w>
75. He, K., Zhang, X., Ren, S., & Sun, J. (2015). Delving Deep into Rectifiers: Surpassing Human-Level Performance on ImageNet Classification. *ArXiv (Cornell University)*. <https://doi.org/10.48550/arxiv.1502.01852>
76. Tung M.Phung. (n.d.). *ELU activation: A comprehensive analysis*. Tung M Phung’s Blog. <https://tungmphung.com/elu-activation-a-comprehensive-analysis/>
77. Dabal Pedamonti. (2018). Comparison of non-linear activation functions for deep neural networks on MNIST classification task. *ArXiv (Cornell University)*. <https://doi.org/10.48550/arxiv.1804.02763>
78. Yingge, H., Ali, I., & Lee, K.-Y. (2020). Deep Neural Networks on Chip - A Survey. *2020 IEEE International Conference on Big Data and Smart Computing (BigComp)*. <https://doi.org/10.1109/bigcomp48618.2020.00016>
79. Zafar, A., Aamir, M., Mohd Nawari, N., Arshad, A., Riaz, S., Alruban, A., Dutta, A. K., & Almotairi, S. (2022). A Comparison of Pooling Methods for Convolutional Neural Networks. *Applied Sciences*, 12(17), 8643. <https://doi.org/10.3390/app12178643>
80. Thakur, A. (2023, April 28). *Keras Dense Layer: How to Use It Correctly*. W&B. <https://wandb.ai/ayush-thakur/keras-dense/reports/Keras-Dense-Layer-How-to-Use-It-Correctly--Vmlldzo0MjAzNDY1>
81. Wei, J. (2019, July 3). *AlexNet: The Architecture that Challenged CNNs*. Medium. <https://towardsdatascience.com/alexnet-the-architecture-that-challenged-cnns-e406d5297951>
82. Li, J., Ablan, C., Wu, R., Guan, S., & Yao, J. (2021). Preprocessing Techniques’ Effect On Overfitting for VGG16 Fast-RCNN Pistol Detection. *IJCA*, 28(1). <https://thescholarship.ecu.edu/bitstream/handle/10342/10847/RuiPreprocessingTechniquesEffectOnOverfittingforVGG16FastRCNNPistolDetection.pdf?sequence=1&isAllowed=y>

83. Basha, S. H. S., Dubey, S. R., Pulabaigari, V., & Mukherjee, S. (2019). Impact of fully connected layers on performance of convolutional neural networks for image classification. *Neurocomputing*. <https://doi.org/10.1016/j.neucom.2019.10.008>
84. *Introduction to deep learning: Bonus material*. (n.d.). Carpentries-Incubator.github.io. Retrieved January 9, 2024, from <https://carpentries-incubator.github.io/deep-learning-intro/instructor/bonus-material.html>
85. Es-sabery, F., Hair, A., Qadir, J., Sainz-De-Abajo, B., Begonya Garcia-Zapirain, & Isabel. (2021). Sentence-Level Classification Using Parallel Fuzzy Deep Learning Classifier. *IEEE Access*, 9, 17943–17985. <https://doi.org/10.1109/access.2021.3053917>
86. Nwankpa, C., Ijomah, W., Gachagan, A., & Marshall, S. (2018). Activation functions: Comparison of trends in practice and research for deep learning. *arXiv preprint arXiv:1811.03378*.
87. Mahendran, N. (2021). Analysis of memory consumption by neural networks based on hyperparameters. *arXiv*. <https://doi.org/10.48550/arXiv.2110.11424>
88. Pang, B., Nijkamp, E., & Wu, Y. N. (2019). Deep Learning With TensorFlow: A Review. *Journal of Educational and Behavioral Statistics*, 45(2), 227–248. <https://doi.org/10.3102/1076998619872761>
89. *ADNI | Alzheimer's Disease Neuroimaging Initiative*. (n.d.). ADNI. <https://adni.loni.usc.edu/>
90. *Alzheimers.net*. (2013). Alzheimers.net. <https://www.alzheimers.net/>
91. *MRI and Alzheimers*. (n.d.). www.kaggle.com. <https://www.kaggle.com/datasets/jboysen/mri-and-alzheimers>
92. Kamal, Md. S., Northcote, A., Chowdhury, L., Dey, N., Crespo, R. G., & Herrera-Viedma, E. (2021). Alzheimer's Patient Analysis Using Image and Gene Expression Data and Explainable-AI to Present Associated Genes. *IEEE Transactions on Instrumentation and Measurement*, 70, 1–7. <https://doi.org/10.1109/tim.2021.3107056>
93. *Alzheimer's Disease and Healthy Aging Data*. (2022, May 24). Data.gov; Centers for Disease Control and Prevention. <https://catalog.data.gov/dataset/alzheimers-disease-and-healthy-aging-data>
94. Bae, J. B., Lee, S., Jung, W., Park, S., Kim, W., Oh, H., Han, J. W., Kim, G. E., Kim, J. S., Kim, J. H., & Kim, K. W. (2020). Identification of Alzheimer's disease using a convolutional neural network model based on T1-weighted magnetic resonance imaging. *Scientific Reports*, 10(1), 22252. <https://doi.org/10.1038/s41598-020-79243-9>
95. *The final EPAD dataset is now available on the Alzheimer's Disease Workbench*. (n.d.). CORDIS | European Commission. Retrieved January 10, 2024, from <https://cordis.europa.eu/article/id/429468-the-final-epad-dataset-is-now-available-on-the-alzheimer-s-disease-workbench>
96. *TensorFlow Pneumonia Classification on X-rays*. (n.d.). Kaggle.com. Retrieved December 12, 2023, from <https://www.kaggle.com/code/amyjang/tensorflow-pneumonia-classification-on-x-rays/notebook>
97. Google. (2019). *Classification: ROC Curve and AUC | Machine Learning Crash Course*. Google Developers. <https://developers.google.com/machine-learning/crash-course/classification/roc-and-auc>
98. Kumar, R., & Indrayan, A. (2011). Receiver operating characteristic (ROC) curve for medical researchers. *Indian Pediatrics*, 48(4), 277–287. <https://doi.org/10.1007/s13312-011-0055-4>
99. Hicks, S. A., Strümke, I., Thambawita, V., Hammou, M., Riegler, M. A., Halvorsen, P., & Parasa, S. (2022). On evaluation metrics for medical applications of artificial intelligence. *Scientific Reports*, 12(1), 5979. <https://doi.org/10.1038/s41598-022-09954-8>
100. Mesinovic, M., & Yang, K. (2022). Multi-label Neural Model for Prediction of Myocardial Infarction Complications with Resampling and Explainability. *2022 IEEE-EMBS International Conference on Biomedical and Health Informatics (BHI)*, 01–05. <https://doi.org/10.1109/BHI56158.2022.9926915>
101. Yessou, H., Sumbul, G., & Demir, B. (2020). A Comparative Study of Deep Learning Loss Functions for Multi-Label Remote Sensing Image Classification. *IGARSS 2020 - 2020 IEEE International Geoscience and Remote Sensing Symposium*, 1349–1352. <https://doi.org/10.1109/IGARSS39084.2020.9323583>
102. Haghghi, S., Jasemi, M., Hessabi, S., & Zolanvari, A. (2018). PyCM: Multiclass confusion matrix library in Python. *J. Open Source Softw.*, 3, 729. <https://doi.org/10.21105/JOSS.00729>
103. Sharma, D. K., Chatterjee, M., Kaur, G., & Vavilala, S. (2022). Deep learning applications for disease diagnosis. *Deep Learning for Medical Applications with Unique Data*, 31–51. <https://doi.org/10.1016/b978-0-12-824145-5.00005-8>

- 104.Selvaraju, R., Das, A., Vedantam, R., Cogswell, M., Parikh, D., & Batra, D. (2016). Grad-CAM: Visual Explanations from Deep Networks via Gradient-Based Localization. *International Journal of Computer Vision*, 128, 336-359. <https://doi.org/10.1007/s11263-019-01228-7>.
- 105.Lin, T., & Lee, H. (2020). Covid-19 Chest Radiography Images Analysis Based on Integration of Image Preprocess, Guided Grad-CAM, Machine Learning and Risk Management. *Proceedings of the 4th International Conference on Medical and Health Informatics*. <https://doi.org/10.1145/3418094.3418096>.
- 106.Xavier, A., Villavicencio, C., Macrohon, J., Jeng, J., & Hsieh, J. (2022). Object Detection via Gradient-Based Mask R-CNN Using Machine Learning Algorithms. *Machines*. <https://doi.org/10.3390/machines10050340>.
- 107.Debowski M, Brain lobes - annotated MRI. Case study, *Radiopaedia.org* (Accessed on 25 Jan 2024) <https://doi.org/10.53347/rID-61691>
- 108.Hall, A. M., Moore, R. Y., Lopez, O. L., Kuller, L., & Becker, J. T. (2008). Basal forebrain atrophy is a presymptomatic marker for Alzheimer's disease. *Alzheimer's & Dementia*, 4(4), 271–279. <https://doi.org/10.1016/j.jalz.2008.04.005>
- 109.Bogaard, S. J. A., Dumas, E. M., Acharya, T. P., Johnson, H., Langbehn, D. R., Scahill, R. I., Tabrizi, S. J., Buchem, M. A., Grond, J., & Roos, R. A. C. (2010). Early atrophy of pallidum and accumbens nucleus in Huntington's disease. *Journal of Neurology*, 258(3), 412–420. <https://doi.org/10.1007/s00415-010-5768-0>
- 110.*Alzheimer MRI Model - group 7*. (n.d.). Kaggle.com. Retrieved February 1, 2024, from <https://www.kaggle.com/code/davidebombassei/alzheimer-mri-model-group-7>
- 111.*Alzheimer's Disease Classification Notebook*. (n.d.). Kaggle.com. Retrieved February 1, 2024, from <https://www.kaggle.com/code/vishakansubramanian/alzheimer-s-disease-classification-notebook/notebook>
- 112.Nasser, M., & Yusof, U. K. (2023). Deep Learning Based Methods for Breast Cancer Diagnosis: A Systematic Review and Future Direction. *Diagnostics (Basel, Switzerland)*, 13(1), 161. <https://doi.org/10.3390/diagnostics13010161>
- 113.Wehebe, R. M., Katsaggleos, A. K., Hammond, K. J., Hong, H., Ahmad, F., Ouyang, D., Shah, S. J., McCarthy, P. M., & Thomas, J. D. (2023). Deep Learning for Cardiovascular Imaging. *JAMA Cardiology*, 8(11), 1089–1089. <https://doi.org/10.1001/jamacardio.2023.3142>
- 114.Jo, T., Nho, K., & Saykin, A. J. (2019). Deep Learning in Alzheimer's Disease: Diagnostic Classification and Prognostic Prediction Using Neuroimaging Data. *Frontiers in Aging Neuroscience*, 11. <https://doi.org/10.3389/fnagi.2019.00220>
- 115.Chen, T., Su, Z.-H., Liu, Z., Wang, M., Cui, Z.-F., Zhao, L., Yang, L.-J., Zhang, W.-C., Liu, X., Liu, J., Tan, S.-Y., Li, S.-L., Feng, Q.-J., Pang, S.-M., & Lu, H. (2022). Automated Magnetic Resonance Image Segmentation of Spinal Structures at the L4-5 Level with Deep Learning: 3D Reconstruction of Lumbar Intervertebral Foramen. *Orthopaedic Surgery*, 14(9), 2256–2264. <https://doi.org/10.1111/os.13431>
- 116.Alzheimer MRI Preprocessed Dataset. (n.d.). Www.kaggle.com. <https://www.kaggle.com/datasets/sachinkumar413/alzheimer-mri-dataset/data>