



NATIONAL TECHNICAL UNIVERSITY OF ATHENS
SCHOOL OF ELECTRICAL AND COMPUTER ENGINEERING
DEPARTMENT OF INFORMATION TRANSMISSION SYSTEMS AND MATERIAL
TECHNOLOGY

**Development of a convolutional neural network model to
predict mental fatigue levels from EEG data**

Diploma Thesis

Manousos A. Manouras

Supervisor: George Matsopoulos, Professor

Athens July 2023



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ
ΤΟΜΕΑΣ ΗΛΕΚΤΡΟΜΑΓΝΗΤΙΚΩΝ ΕΦΑΡΜΟΓΩΝ ΗΛΕΚΤΡΟΟΠΤΙΚΗΣ ΚΑΙ
ΗΛΕΚΤΡΟΝΙΚΩΝ ΥΛΙΚΩΝ

**Ανάπτυξη μοντέλου πρόβλεψης επιπέδου νοητικής κόπωσης
με χρήση νευρωνικών δικτύων σε δεδομένα
ηλεκτροεγκεφαλογραφήματος**

Διπλωματική Εργασία

Μανούσος Α. Μανούρας

Επιβλέπων: Γεώργιος Ματσόπουλος , Καθηγητής Μελος Δ.Ε.Π.

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 12η Ιουλίου 2023:

Γεώργιος Ματσόπουλος
Καθηγητής Μελος Δ.Ε.Π.

Παναγιώτης Τσανάκας
Καθηγητής Μελος Δ.Ε.Π.

Αθανάσιος Παναγόπουλος
Καθηγητής Μελος Δ.Ε.Π.

Αθήνα Ιούλιος 2023

Μανούσος Α. Μανουράς

Διπλωματούχος Ηλεκτρολόγος Μηχανικός και Μηχανικός υπολογιστών Ε.Μ.Π

Copyright © Μανούσος Μανουράς 2023

Με επιφύλαξη παντός δικαιώματος. All rights reserved.

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

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

Περίληψη

Η παρούσα διπλωματική εργασία δημιουργήθηκε με αφορμή ένα πείραμα που πραγματοποιήθηκε στο 401 Γενικό Στρατιωτικό Νοσοκομείο Αθηνών κατά το οποίο 20 εργαζόμενοι υποβλήθηκαν σε ηλεκτροεγκεφαλογράφημα (EEG) εκτελώντας διεργασίες λειτουργικής μνήμης(N-Back). Ο κάθε συμμετέχοντας πραγματοποίησε καταγραφές σε κατάσταση στέρησης ύπνου και σε κατάσταση ξεκούρασης.

Στόχος της εργασίας είναι η δημιουργία ενός μοντέλου τεχνητής νοημοσύνης που αξιοποιεί τα δεδομένα του κάθε εγκ/τος (EEG) με σκοπό να προβλέψει την κατάσταση που βρισκόταν ο συμμετέχοντας όταν υπεβλήθη σε αυτό. Το μοντέλο αυτό χρησιμοποιεί βαθιά συνελκτικά νευρωνικά δίκτυα(CNN) και είναι ανεπτυγμένο σε γλώσσα προγραμματισμού python με την βιβλιοθήκη keras.

Λέξεις-κλειδιά:

HEG, EEG, CNN, νευρωνικά δίκτυα, εγκεφαλος, επίπεδα κόπωσης

Abstract

The present thesis was created based on an experiment that was conducted at the 401 General Military Hospital of Athens in which an electroencephalogram (EEG) was performed on 20 workers of the hospital while completing functional memory tests (N-Back). Recordings were made for each participant in a sleep deprivation state and a rested state.

The aim of this work is to create an artificial intelligence model that utilizes the data of each electroencephalogram (EEG) in order to predict the state the participant was in when they underwent the test. This model uses deep convolutional neural networks (CNN) and is developed in the python programming language using the keras library.

Keywords:

EEG, CNN, neural networks, mental fatigue, N-Back

Ευχαριστίες

Στην μητέρα μου

Πίνακας περιεχομένων

Περίληψη	vi
Abstract	vii
Ευχαριστίες	ix
Πίνακας περιεχομένων	xi
Λίστα εικόνων	xv
1 Εισαγωγή	1
1.1 Αντικείμενο της διπλωματικής	1
1.2 Οργάνωση του τόμου	2
2 Εγκέφαλος και ΗΕΓ	3
2.1 Ηλεκτροφυσιολογία εγκεφάλου	3
2.1.1 Χαρακτηριστικά Νευρώνα	4
2.2 Ηλεκτροεγκεφαλογράφημα	6
2.2.1 Ιστορική αναδρομή και περιγραφή	6
2.2.2 Διαδικασία ΗΕΓ και τοποθέτηση ηλεκτροδίων	7
2.2.3 Στάδια καταγραφής ΗΕΓ	8
2.2.4 Βασικοί ρυθμοί ΗΕΓ	9
2.2.5 Προκλητά Δυναμικά	12
3 Τεχνητή νοημοσύνη και Νευρωνικά δίκτυα	15
3.1 Πεδία της τεχνητής νοημοσύνης	15
3.1.1 Τεχνητή νοημοσύνη	15

3.1.2	Μηχανική μάθηση (Machine Learning)	17
3.1.3	Βαθιά μάθηση (Deep Learning)	18
3.2	Χαρακτηριστικά Νευρωνικών Δικτύων	19
3.2.1	Τεχνητός Νευρώνας Perceptron	20
3.2.2	Συναρτήσεις Ενεργοποίησης	21
3.2.3	Συνάρτηση Λάθους	22
3.2.4	Στοιχεία Συνελκτικού Νευρωνικού Δικτύου(CNN)	23
4	Σχεδίαση μοντέλου και προεπεξεργασία δεδομένων	25
4.1	Δεδομένα μοντέλου	25
4.1.1	N-Back	25
4.1.2	Συλλογή δεδομένων	27
4.2	Προεπεξεργασία(preprocessing)	27
4.2.1	Τεχνικές Διόρθωσης των artifacts	28
4.2.2	Προεπεξεργασία δεδομένων πειράματος	31
4.3	Σχεδιασμός μοντέλου	31
4.3.1	Δεδομένα εισόδου	31
4.3.2	Αρχιτεκτονική μοντέλου	33
5	Αποτελέσματα	35
5.1	Αποτελέσματα	35
6	Παρατηρήσεις	37
6.1	Παρατηρήσεις	37
6.1.1	Διαφορετικές προσεγγίσεις	37
6.1.2	Διαχωρισμός απαντήσεων	38
7	Συμπεράσματα	39
7.1	Συμπεράσματα	39
7.1.1	Μελλοντικές Προεκτάσεις	40
	Bibliography	41
	APPENDICES	45

A Κωδικας	47
A.1 Βασικός κώδικας	47
A.2 Βοηθητικές συναρτήσεις	51
A.3 Imports	55

Λίστα εικόνων

2.1	Σχηματική αναπαράσταση νευρώνα	4
2.2	Συνάρτηση χρόνου και δυναμικού μεμβράνης	5
2.3	Θέσεις και ονόματα ηλεκτοδίων με βάση το σύστημα 10-20	7
2.4	Διαδικασία ψηφιοποίησης ΗΕΙ	9
2.5	Πίνακας Συχνοτήτων και πλατών των κυριότερων ρυθμών	9
2.6	Κυματομορφές των κυριότερων ρυθμών	10
3.1	Πεδία της τεχνητής νοημοσύνης	16
3.2	Σχηματική αναπαράσταση βαθιού νευρονικού δικτύου	18
3.3	Σχηματική αναπαράσταση perceptron	20
3.4	Βασικότερες συναρτήσεις ενεργοποίησης	22
4.1	Παράδειγμα ακολουθείας οπτικών ερεθισμάτων της διεργασίας (σωστή ακου- λουθία απαντήσεων ξεκινώντας από την 3η εικόνα: 1,2,4,3)	26
4.2	Βήματα μεθόδου Ανάλυσης ανεξάρτητων συνιστωσών	30
4.3	Παράδειγμα μορφής πίνακα καταγραφών (5 πρώτες γραμμές)	32
4.4	Τιμές υπερπαραμέτρων μοντέλου	33
4.5	Model summary	34
5.1	Διακύμανση της ακρίβειας των αποτελεσμάτων	35
5.2	Πίνακας Σύγκρισης αποτελεσμάτων	36
5.3	Στατιστικά εκπαίδευσης μοντέλου	36

Chapter 1

Εισαγωγή

1.1 Αντικείμενο της διπλωματικής

Η λειτουργία του ανθρώπινου εγκεφάλου, ως μέρος του Κεντρικού νευρικού συστήματος (ΚΝΣ), είναι να ρυθμίσει τις περισσότερες λειτουργίες του σώματος και του μυαλού. Αυτό περιλαμβάνει τα πάντα, από τις ζωτικές λειτουργίες, όπως η αναπνοή ή ο καρδιακός ρυθμός, περνώντας και σε πιο βασικές λειτουργίες, όπως ο ύπνος και η πείνα, μέχρι και ανώτερες, όπως η σκέψη, η μνήμη ή η ομιλία. Αυτό οδήγησε σε πολλές έρευνες ανά τα χρόνια με σκοπό την περαιτέρω κατανόηση και καταγραφή των διαφορετικών σημάτων που στέλνει ο εγκέφαλος για να πραγματοποιήσει κάποιες από αυτές τις λειτουργίες καθώς και ποιο μέρος του εγκεφάλου είναι υπεύθυνο για κάθε μια από αυτές.

Το ηλεκτροεγκεφαλογράφημα (EEG) είναι ένα ευρέως διαδεδομένο και χρήσιμο εργαλείο για την καταγραφή αυτών των σημάτων και χρησιμοποιείται μεταξύ άλλων για την καταγραφή του πλάτους και συχνότητας των εγκεφαλικών κυμάτων που είναι υπεύθυνα για την προσοχή, την γνωστική επεξεργασία καθώς και για τις καταστάσεις συνείδησης όπως ύπνος, διαλογισμός κ.α. Ωστόσο τα δεδομένα που αντλούνται από αυτό συχνά έρχονται με θορύβους, τόσο εξωγενείς από το περιβάλλον και τις συνθήκες της μέτρησης όσο και από τον ίδιο τον οργανισμό όπως ηλεκτρικοί θόρυβοι από μύες και μάτια, οι οποίοι υποβαθμίζουν την ποιότητα του σήματος και δυσκολεύουν στην κατανόηση του. [1]

Η ραγδαία ανάπτυξη στον τομέα της τεχνητής νοημοσύνης (AI) και της μηχανικής μάθησης (ML) τα τελευταία χρόνια έχει οδηγήσει στην προσπάθεια ανάπτυξης τέτοιων μοντέλων για την βελτίωση των δεδομένων που αντλούνται από το EEG. Συγκεκριμένα, με την χρήση τεχνικών βαθιάς μάθησης επιτυγχάνεται η αυτόματη αναγνώριση και ταξινόμηση μοτίβων,

η εξαγωγή βασικών χαρακτηριστικών από τα δεδομένα καθώς και η πρόβλεψη διαφορετικών καταστάσεων και τυχών παθήσεων του εγκεφάλου. Μελέτες έχουν δείξει ότι τεχνικές βαθιάς μάθησης και AI σε EEG δεδομένα, που καταγράφηκαν κατά τη διάρκεια εργασιών λειτουργικής μνήμης, είχαν μεγάλη ακρίβεια στην αναγνώριση διαφορετικών γνωστικών καταστάσεων. [2, 3]

1.2 Οργάνωση του τόμου

Στο πρώτο κεφάλαιο περιγράφεται η φυσιολογία του εγκεφάλου και η χρήση του ηλ/τος για την παρακολούθηση αυτού. Το δεύτερο κεφάλαιο αναλύει τον ρόλο της τεχνητής νοημοσύνης στην επίλυση προβλημάτων και ειδικότερα επικεντρώνεται στα βασικότερα χαρακτηριστικά των συνελκτικών νευρωνικών δικτύων. Το επόμενο κεφάλαιο δίνει περισσότερες πληροφορίες για το πείραμα καθώς και για την προ-επεξεργασία των δεδομένων πριν την είσοδο τους στο μοντέλο. Στη συνέχεια παρατίθενται τα αποτελέσματα και η εξέλιξη του μοντέλου και τέλος αναλύονται τα συμπεράσματα και οι μελλοντικές προεκτάσεις του μοντέλου. Ο κώδικας μπορεί να βρεθεί στο υπόμνημα [A](#).

Chapter 2

Εγκέφαλος και ΗΕΓ

2.1 Ηλεκτροφυσιολογία εγκεφάλου

Ο ανθρώπινος εγκέφαλος αποτελεί χωρίς αμφιβολία το πλέον πολύπλοκο δημιούργημα της φύσης. Αποτελείται από ένα εξαιρετικά πολύ-σύνθετο δίκτυο κύτταρων, οι λειτουργίες του οποίου είναι υπεύθυνες για τη δημιουργία των σκέψεων, της μνήμης, τον έλεγχο των δραστηριοτήτων του σώματος και των συναισθημάτων. Αυτό το έργο επιτελείται από τους περίπου 10^{10} νευρώνες του εγκεφάλου, οι οποίοι συναντιούνται μεταξύ τους σε 10^{14} έως 10^{15} σημεία [4].

Η ηλεκτρική δραστηριότητα του εγκεφάλου οφείλεται σε ιοντικά ρεύματα που προέρχονται από μία σειρά βιοχημικών διαδικασιών που λαμβάνουν χώρα σε κυτταρικό επίπεδο. Τα κύτταρα που ευθύνονται για αυτή τη δραστηριότητα ονομάζονται νευρώνες (σχήμα 2.1) και αποτελούνται από το σώμα, τους δενδρίτες και τον άξονα. Οι δενδρίτες σχηματίζουν δομές που διακλαδίζονται από το κυρίως σώμα του κυττάρου προς τα έξω. Οι περισσότερες συνάψεις, τα σημεία δηλαδή τα οποία λαμβάνουν τα σήματα από τους άλλους νευρώνες, βρίσκονται στους δενδρίτες και το κυρίως σώμα του κυττάρου. Ο άξονας ή νευρική ίνα, αποτελεί μια προέκταση του κυτταρικού σώματος. Το τμήμα του άξονα που βρίσκεται πλησιέστερα στο σώμα του κυττάρου, μαζί με το σημείο όπου γίνεται η σύνδεση, ονομάζεται αρχικό τμήμα. Από το σημείο αυτό, ξεκινούν τα ηλεκτρικά σήματα που διαδίδονται μακριά από το σώμα, κατά μήκος του άξονα. Ο άξονας επίσης μπορεί να έχει και άλλες εγκάρσιες διακλαδώσεις ενώ στις απολήξεις τόσο του άξονα, όσο και των διακλαδώσεων υπάρχουν περαιτέρω διακλαδώσεις. Όλες οι διακλαδώσεις καταλήγουν σε απολήξεις που είναι υπεύθυνες για την μεταβίβαση των χημικών σημάτων από τους νευρώνες.

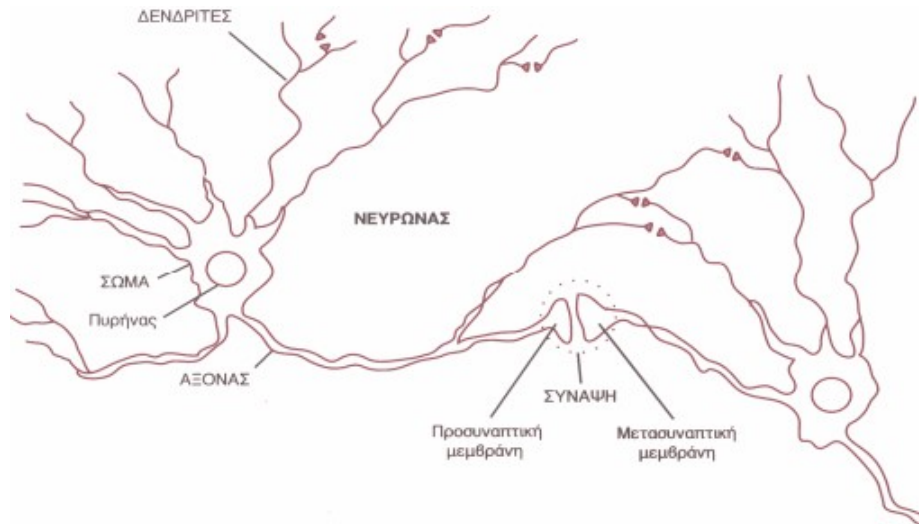


Figure 2.1: Σχηματική αναπαράσταση νευρώνα

2.1.1 Χαρακτηριστικά Νευρώνα

Ο νευρώνας μαζί με τον άξονα και τους δενδρίτες καλύπτεται από μία κυτταρική μεμβράνη πάχους 8-10nm η οποία παρουσιάζει μια επιλεκτική διαπερατότητα ιόντων. Σε κατάσταση ηρεμίας κατά μήκος της μεμβράνης των κυττάρων η συγκέντρωση του εσωκυττάρου χώρου σε ιόντα καλίου(K^+) και νατρίου(Na^+) είναι διαφορετική από αυτήν του εξωκυττάρου με αποτέλεσμα να διατηρείται μια διαφορά δυναμικού (πόλωση της μεμβράνης) γύρω στα $-70mV$ στον εσωτερικό ως προς τον εξωτερικό χώρο εξαιτίας της άνισης κατανομής των ιόντων μεταξύ των δύο πλευρών της μεμβράνης η οποία υφίσταται λόγω της μεταβολικής δραστηριότητας του κυττάρου. Τα δυναμικά που μετρούνται μεταξύ δύο ηλεκτροδίων στην επιφάνεια του δέρματος της κεφαλής είναι αποτέλεσμα της διέλευσης των ιόντων διαμέσου της κυτταρικής μεμβράνης. Τα ρεύματα διαχέονται από τα σημεία της δημιουργίας τους έως την εξωτερική δερματική επιφάνεια μιας και ο εγκεφαλικός ιστός, το δέρμα, το κρανίο άγουν το ηλεκτρικό ρεύμα. Η μετάδοση και επεξεργασία πληροφορίας σχετίζεται με δύο είδη διαμεμβρανικής ρευματικής ροής που προκαλούν τελικά τα εξής διαφορετικής φύσης δυναμικά: Δυναμικό δράσης(action potential) και μετασυναπτικό δυναμικό(post synaptic potential).

Το δυναμικό δράσης προκαλείται όταν το διαμεμβρανικό δυναμικό στο σώμα του νευρώνα αλλάξει από την τιμή ηρεμίας και περάσει ένα ορισμένο κατώφλι(συνήθως $-50mV$. Είναι ταχείες μεταβολές του δυναμικού της μεμβράνης οι οποίες μπορεί να διαρκέσουν μόνο 1 ms, κατά τη διάρκεια του οποίου όμως το δυναμικό της μεμβράνης μπορεί να μεταβληθεί μέχρι και κατά $100mV$ και μετά να επαναπολωθεί στη τιμή του δυναμικού ηρεμίας (σχήμα

2.2). Αυτή η κρουστική ώση διαδίδεται ταχύτατα κατά μήκος του άξονα, αναπαράγοντας αυτόν τον κύκλο πόλωσης- αποπόλωσης μέσα και έξω από την κυτταρική μεμβράνη χωρίς να εξασθενεί κατά την διάδοση.




Figure 2.2: Συνάρτηση χρόνου και δυναμικού μεμβράνης

Το μετασυναπτικό δυναμικό εμφανίζεται στη μετασυναπτική μεμβράνη, όταν μεταδοθεί ο ερεθισμός μέσω του συναπτικού χάσματος από την προσυναπτική μεμβράνη που οφείλεται σε ενεργοποίηση του προσυναπτικού νευρώνα. Σε σχέση με το δυναμικό δράσης, έχει πιο συνεχή μορφολογία, είναι πιο περιορισμένο στο χώρο (αφού εμφανίζεται στην περιοχή της σύναψης) και έχει χαμηλότερη τιμή, διότι η μετασυναπτική μεμβράνη αποπολώνεται ή υπερπολώνεται λιγότερο σε σχέση με το σώμα του νευρώνα καθώς εκεί αθροίζονται όλα τα σήματα που προέρχονται από τους δενδρίτες. Κατά τη διάρκεια της αποπόλωσης το δυναμικό ονομάζεται μετασυναπτικό δυναμικό διέγερσης (EPSP), ενώ στην αντίθετη περίπτωση το δυναμικό ονομάζεται μετασυναπτικό δυναμικό καταστολής ή αναστολής (APSP). Σε μια σύναψη του εγκεφάλου μπορεί να εμφανιστεί είτε μόνο μετασυναπτικό δυναμικό διέγερσης, οπότε η σύναψη ονομάζεται σύναψη διέγερσης ή διεγείρουσα σύναψη (excitatory synapse) είτε μόνο μετασυναπτικό δυναμικό καταστολής ή αναστολής οπότε αυτή ονομάζεται κατασταλτική ή ανασταλτική σύναψη (inhibitory synapse).

Το σύνολο των ηλεκτροχημικών επιδράσεων από νευρώνα σε νευρώνα, αθροιζόμενο για όλες τις περιοχές του εγκεφάλου, μέσα από ένα δίκτυο ανεξερεύνητης ακόμη πολυπλοκότητας, δημιουργεί αυτό που ονομάζουμε εγκεφαλική λειτουργία, της οποίας μόνο μερικώς μπορούμε να ανιχνεύσουμε και να μελετήσουμε τις διάφορες διαδικασίες και εκδηλώσεις. Ένα από τα εργαλεία για τη μελέτη αυτή όπως αναφέραμε και στην εισαγωγή, αποτελεί ακριβώς η Ηλεκτροεγκεφαλογραφία. [4]

2.2 Ηλεκτροεγκεφαλογράφημα

2.2.1 Ιστορική αναδρομή και περιγραφή

Η πρώτη εμπειρισταωμένη αναφορά για την τεχνική που χρησιμοποιείται για την καταγραφή διαφορών δυναμικού στην εξωτερική επιφάνεια του ανθρώπινου κεφαλιού προέρχεται από το Γερμανό ψυχίατρο Hans Berger [5] το 1929, γεγονός που οριοθετεί την έναρξη της καταγραφής και μελέτης των λειτουργιών του εγκεφάλου μέσω του ηλεκτροεγκεφαλογραφήματος. Ο Hans Berger με την τοποθέτηση δύο λεπτών φύλλων αλουμινίου στο μέτωπο και στο πίσω μέρος του κεφαλιού, που έπαιξαν το ρόλο των ηλεκτροδίων, κατέγραψε διαφορές δυναμικού στην επιφάνεια του κεφαλιού κατασκευάζοντας έτσι μία πρωτογενή μορφή καταγραφικού συστήματος ηλεκτροεγκεφαλογράφου. [6]

Το ΗΕΓ στηρίζεται στην καταγραφή των διαφορών δυναμικού, οι οποίες παρουσιάζονται σε σημεία της εξωτερικής δερματικής επιφάνειας του ανθρώπινου κεφαλιού. Τα δυναμικά τα οποία μετρούμε μεταξύ δύο ηλεκτροδίων στην εξωτερική δερματική επιφάνεια του κεφαλιού οφείλονται ουσιαστικά σε ρεύματα ιόντων διαμέσου της κυτταρικής μεμβράνης των νευρώνων που συμμετέχουν στην εκάστοτε εγκεφαλική διεργασία. Η παρεμβολή μεταξύ του ηλεκτροδίου και του εγκεφάλου ενός στρώματος πάχους 2-3 cm (δέρμα, κρανίο, σκληρά μήνιγγα) εξασθενεί το σήμα κατά 10 τουλάχιστον φορές. Είναι απαραίτητη η ενίσχυση των σημάτων αυτών για καλύτερη απεικόνιση καθώς και η πυκνότερη κάλυψη του κεφαλιού με απαγωγή ηλεκτρόδια για μεγαλύτερη ακρίβεια και εποπτεία της εγκεφαλικής λειτουργίας [5]. Η ενίσχυση και η καταγραφή αυτών των κυμάτων, που αντιπροσωπεύουν ένα άθροισμα ταυτόχρονων ηλεκτρικών αλλαγών πολλών εγκεφαλικών κυττάρων αποτελεί το «ηλεκτροεγκεφαλογράφημα» (ΗΕΓ).

2.2.2 Διαδικασία ΗΕΓ και τοποθέτηση ηλεκτροδίων

Το πρώτο στάδιο στην εξαγωγή των σημάτων του EEG αποτελούν τα ηλεκτρόδια, οι αισθητήρες του συστήματος, οι οποίοι μετατρέπουν το ρεύμα ιόντων μέσα στο ανθρώπινο σώμα σε ρεύμα ηλεκτρονίων μέσα στα καλώδια, τα οποία μετά οδηγούν αυτό το ρεύμα σε επόμενα στάδια επεξεργασίας. Συνήθως χρησιμοποιούνται ηλεκτρόδια που κατασκευάζονται από άργυρο (Ag) και χλωριούχο άργυρο (AgCl). Η επαφή τους με το δέρμα γίνεται μέσω μίας κολλώδους αγώγιμης ουσίας (gel), που συνήθως συνίσταται από ανιόντα χλωρίου (Cl⁻), μέσω ενός μικρού δακτυλιδιού, που από τη μια μεριά προσκολλάται στο δέρμα και από την άλλη στο κυρίως ηλεκτρόδιο. Τα ονόματα και οι θέσεις των ηλεκτροδίων δεν είναι αυθαίρετα, αλλά καθορίζονται από το Διεθνές Σύστημα Τοποθέτησης 10-20 (International 10-20 Placement System) για τις περισσότερες κλινικές και ερευνητικές εφαρμογές, έτσι ώστε να διασφαλίζεται η κοινή ονομασία των ηλεκτροδίων καθώς και η δυνατότητα αναπαραγωγής των μελετών μεταξύ διαφορετικών εργαστηρίων, χωρίς να υπάρχουν προβλήματα συνάφειας. [7] Το '10' και το '20' στο όνομα του συστήματος αναφέρονται στο γεγονός ότι η απόσταση μεταξύ γειτονικών ηλεκτροδίων αντιστοιχεί είτε στο 10% είτε στο 20% της συνολικής απόστασης του κρανίου από το μπροστινό έως και το πίσω αλλά και από το δεξί έως και το αριστερό μέρος (front-back and right-left distance). Κάθε τοποθεσία του ηλεκτροδίου έχει ένα γράμμα για να αναγνωρίζεται σε ποιο λοβό βρίσκεται και έναν αριθμό για να προσδιορίσει τη θέση του στο ημισφαίριο. Τα γράμματα F, T, C, P, O αντιπροσωπεύ-




Figure 2.3: Θέσεις και ονόματα ηλεκτροδίων με βάση το σύστημα 10-20

ουν τους μετωπικούς (Frontal), κροταφικούς (Temporal), κεντρικούς (Central), βρεγματικούς

(Parietal) και ινιακούς (Occipital) λοβούς αντίστοιχα. Σημειώνεται ότι δεν υπάρχει κεντρικός λοβός, το γράμμα "C" χρησιμοποιείται μόνο για σκοπούς αναγνώρισης. Οι άρτιοι αριθμοί (2, 4, 6, 8) αναφέρονται σε θέσεις ηλεκτροδίων στο δεξιό ημισφαίριο, ενώ οι περιττοί αριθμοί (1, 3, 5, 7) αναφέρονται σε θέσεις του αριστερού ημισφαιρίου. Το γράμμα 'z' αναγράφεται στους αισθητήρες εκείνους που τοποθετούνται στην μεσαία γραμμή. Εκτός από αυτές τις ονομασίες, οι κωδικοί των χαρακτήρων A, P_g και F_p αναφέρονται στους λοβούς του αυτιού, στις ρινοφαρυγγικές και στις εμπρόσθιες πολικές περιοχές αντίστοιχα. [7](σχήμα 2.3)

2.2.3 Στάδια καταγραφής ΗΕΓ

Το σήμα ηλεκτροεγκεφαλογραφήματος το οποίο λαμβάνεται από τα ηλεκτρόδια είναι ασθενές από περίπου 1μV έως και 100μV και οδηγείται ως είσοδος στην δεύτερη βαθμίδα: τον ενισχυτή. Το σήμα αυτό αποτελείται από πέντε συνιστώσες: Το επιθυμητό βιοδυναμικό, τα μη επιθυμητά βιοδυναμικά, το σήμα παρεμβολής της παροχής ρεύματος 50Hz και τις αρμονικές του και τα σήματα παρεμβολής που προκαλούνται από την επαφή ιστού - ηλεκτροδίου και τον θόρυβο. Ο ενισχυτής για τη μέτρηση του σήματος του ΗΕΓ για να είναι κατάλληλος πρέπει να παρέχει επιλεκτική ενίσχυση του φυσιολογικού σήματος και απόρριψη του υπέρθετου θορύβου και των σημάτων παρεμβολής [8]. Αυτό συνιστά και την είσοδο του διαφορικού ενισχυτή. Το κέρδος του ενισχυτή ορίζεται ως ο λόγος του σήματος εξόδου προς το σήμα εισόδου. Προκειμένου να παραχθεί βέλτιστη ποιότητα σήματος και επαρκές επίπεδο δυναμικού για την περαιτέρω επεξεργασία του σήματος, ο ενισχυτής πρέπει να διαθέτει κέρδος 100-100000. Επιπλέον, πρέπει να διαθέτει βέλτιστο λόγο σήματος προς θόρυβο (SNR), υψηλό λόγο απόρριψης κοινού σήματος (common-mode rejection ratio) (τουλάχιστον 100 Db) και υψηλή τιμή αντίστασης εισόδου (τουλάχιστον 100MΩ), ώστε να μειώνεται η επίδραση του ηλεκτρικού θορύβου περιβάλλοντος. Ο λόγος απόρριψης κοινού σήματος ορίζεται ως ο λόγος του κέρδους του διαφορικού σήματος (που είναι και το επιθυμητό σήμα) προς το κέρδος του κοινού σήματος (αρχικό σήμα εισόδου μεταξύ των εισόδων και της γείωσης). Το προκύπτον σήμα φιλτράρεται από ένα υψιπερατό και ένα βαθυπερατό φίλτρο με χαρακτηριστικά 0.5Hz και 35-70 Hz αντίστοιχα. Το υψιπερατό φίλτρο απορρίπτει χαμηλόσυχνα σήματα που προκαλεί η ηλεκτρική αγωγιμότητα του δέρματος ενώ το βαθυπερατό απορρίπτει ηλεκτρομυογραφικά σήματα. [8] Το φιλτραρισμένο σήμα προκειμένου να καταγραφεί και να αποθηκευτεί στον Η/Υ πρέπει να ψηφιοποιηθεί. Τα κανάλια του αναλογικού σήματος δειγματοληπτούνται συνεχώς, σε δεδομένο χρονικό διάστημα (διά-

στημα δειγματοληψίας) και κάθε δείγμα μετατρέπεται σε μια ψηφιακή αναπαράσταση μέσω του μετατροπέα αναλογικού/ψηφιακού σήματος. Η ανάλυση του μετατροπέα καθορίζεται από το ελάχιστο πλάτος σήματος που πρόκειται να υποβληθεί σε δειγματοληψία. Μετά από την διαδικασία αυτή, το σήμα κβαντοποιείται και τότε από αναλογικό έχει μετατραπεί σε ψηφιακό, οπότε είναι δυνατή η ψηφιακή επεξεργασία του μέσω Η/Υ. (σχήμα 2.4)




Figure 2.4: Διαδικασία ψηφιοποίησης ΗΕΓ

2.2.4 Βασικοί ρυθμοί ΗΕΓ

Ρυθμός	Περιοχή Συχνοτήτων (Hz)	Πλάτος (μV)
Δέλτα	0,5 - 3,5	Έως 100 - 200
Θήτα	4 - 7,5	<30
Άλφα	8 - 12	30-50
Αργός Βήτα	13 - 19	<20
Ταχύς Βήτα	20 - 30	<20
Γάμμα	30 - 70	<20

Figure 2.5: Πίνακας Συχνοτήτων και πλατών των κυριότερων ρυθμών

Η μελέτη του σήματος ΗΕΓ, βασίζεται στην διάκριση των συχνοτικών περιοχών στα λαμβανόμενα σήματα. Οι συχνοτικές αυτές περιοχές χαρακτηρίζονται ως ρυθμοί. Βασικό

χαρακτηριστικό τους είναι οι συχνότητες από τις οποίες αποτελούνται, δηλαδή το φασματικό τους περιεχόμενο. Οι κυριότεροι ρυθμοί είναι οι άλφα, βήτα, θήτα, δέλτα και γάμμα. Οι συχνότητες και τα συνήθη πλάτη αυτών φαίνονται στον Πίνακα 2.5 και τα βασικότερα χαρακτηριστικά καθώς και οι κυματομορφές τους (σχήμα 2.6) παρουσιάζονται παρακάτω.

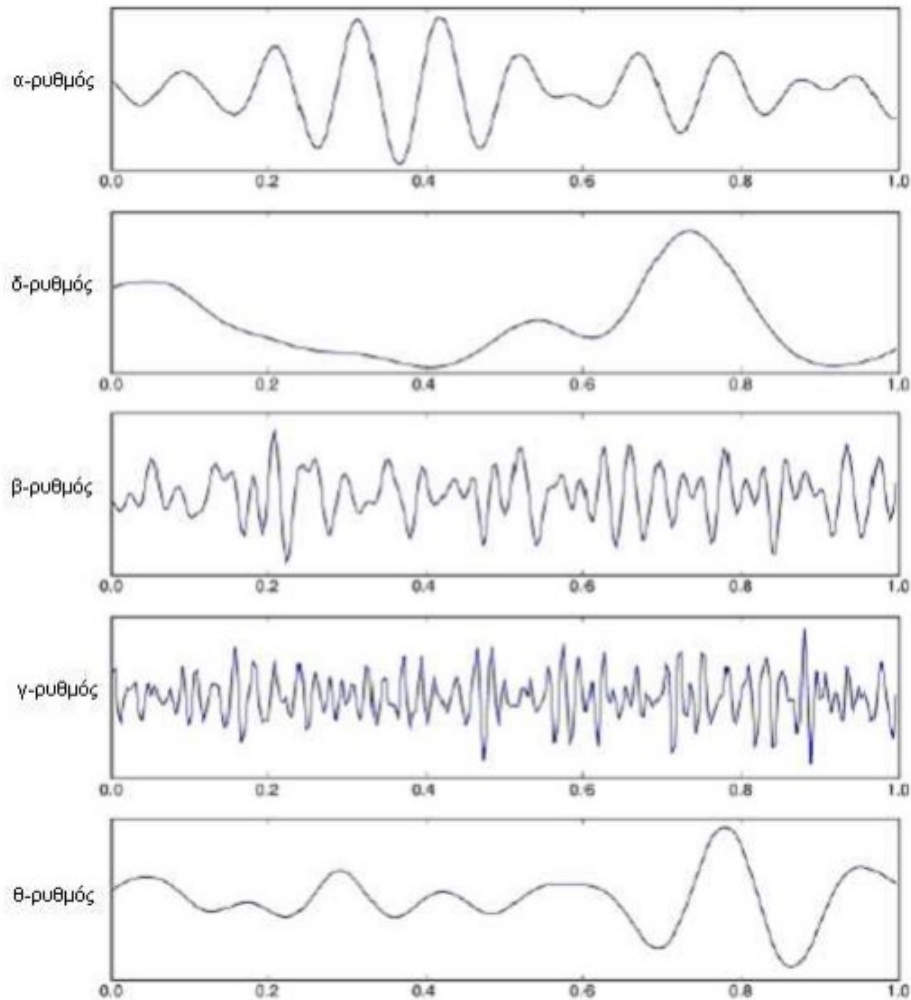


Figure 2.6: Κυματομορφές των κυριότερων ρυθμών

- Άλφα ρυθμός: Πρόκειται για ηλεκτρομαγνητικές ταλαντώσεις στη συχνοτική περιοχή 8 – 13 Hz. Ο ρυθμός αυτός πήρε το όνομά του επειδή ήταν ο πρώτος που μελετήθηκε από τον Hans Berger (1929). Ο α-ρυθμός εντοπίζεται κυρίως στον ινιακό λοβό ενώ είμαστε ξύπνιοι, σε χαλάρωση και με τα μάτια κλειστά, αντιπροσωπεύοντας κατά κάποιο τρόπο τη δραστηριότητα του οπτικού φλοιού απουσία εξωτερικών ερεθισμών. Το κλείσιμο ή το άνοιγμα, των ματιών προκαλεί αύξηση ή μείωση αντίστοιχα, του άλφα ρυθμού. Ο ρυθμός αυτός είναι λιγότερο ή περισσότερο συμμετρικός μεταξύ των ημισφαιρίων αλλά συχνά είναι μεγαλύτερου πλάτους στο μη κυρίαρχο ημισφαίριο. Η

απουσία του άλφα σε ένα από τα δυο ημισφαίρια είναι πάντα παθολογική.

- Βήτα ρυθμός: Με τον όρο αυτό χαρακτηρίζεται η εγκεφαλική ηλεκτρομαγνητική δραστηριότητα που καταγράφεται σε συχνότητες από 13 Hz έως και 30 Hz και εμφανίζεται όταν είμαστε ξύπνιοι σε κατάσταση φυσιολογικής εγρήγορσης. Ποικίλει σημαντικά σε πλάτος και το μέγιστος πλάτος παρατηρείται συνήθως στις εμπρόσθιες κεντρικές περιοχές του εγκεφάλου, αλλά μπορεί να είναι και περισσότερο εκτεταμένος. Τα πλάτη του σε διάφορες συχνοτικές περιοχές έχουν συχνά συσχετιστεί με λειτουργίες όπως η νοητική συγκέντρωση και η σκέψη σε καταστάσεις άγχους. Η εμφάνιση του β-ρυθμού επηρεάζεται επίσης από παθολογικούς παράγοντες και από τη χρήση φαρμάκων .
- Γάμμα ρυθμός: Κατ' αναλογία με τον β-ρυθμό έχουν παρατηρηθεί και οι ταλαντώσεις τύπου γάμμα (γ) (30 – 80 Hz) κυριαρχούν στον εγκέφαλο σε φάσεις λειτουργικής εγρήγορσης. Η δραστηριότητα τύπου γ έχει σχετιστεί με την εστιασμένη εγρήγορση, την κίνηση, τη σωματοαισθητική αντίληψη και πρόβλεψη.
- Δέλτα ρυθμός: Πρόκειται για μεγάλου πλάτους ($\approx 75 \mu V$) και χαμηλής συχνότητας (≤ 4 Hz) ηλεκτρομαγνητικές ταλαντώσεις που φυσιολογικά καταγράφονται στους ενήλικες κατά τα στάδια III και IV του ύπνου ενώ σε κατάσταση εγρήγορσης μόνο σε νεογέννητα έως το δεύτερο έτος της ηλικίας τους. Για την ακρίβεια ο δ-ρυθμός συνιστά ένα ποσοτικό κριτήριο για τη διάκριση ανάμεσα στα στάδια του βαθύ ύπνου: το στάδιο III ορίζεται από την ύπαρξη δ-ρυθμού για ένα χρονικό ποσοστό 20 – 50% ενώ στο στάδιο IV ο ίδιος ρυθμός είναι κυρίαρχος για πάνω από το 50% του χρόνου.
- Θήτα ρυθμός: Ο ρυθμός θήτα (4-8Hz) είναι συνήθως εμφανής στο ΗΕΓ ενηλίκου που δεν κοιμάται, αλλά μπορεί και να μην εμφανίζεται καθόλου. Τείνει να εντοπίζεται περισσότερο στην κεντρική και κροταφική περιοχή και πρέπει η κατανομή του να είναι συμμετρική. Επιπλέον, φαίνεται να συνδέεται με μηχανισμούς καταστολής, είτε στην είσοδο σε φάση χαλάρωσης είτε σε συνδυασμό με το βήτα ρυθμό σε φάση αυξημένης προσοχής. Η παρατήρησή του είναι επίσης πιθανή σε περιπτώσεις εγκεφαλικής βλάβης και σε παθολογικές καταστάσεις όπως η επιληψία. Οι ταλαντώσεις τύπου θ , παρ' όλο που η λειτουργική τους σημασία δεν έχει ξεκαθαριστεί τόσο στον άνθρωπο όσο και στα ζώα, έχουν συσχετιστεί με τις διαδικασίες της διανοητική συγκέντρωσης, της μνήμης και της μάθησης. [9]

2.2.5 Προκλητά Δυναμικά

Τα τελευταία είκοσι έτη παρουσιάζεται αυξημένο ενδιαφέρον για τη μελέτη των εγκεφαλικών διαδικασιών οι οποίες προκαλούνται από συγκεκριμένα γεγονότα. Ονομάζουμε Βιοματικά Δυναμικά - ΒΔ (Event Related Potentials - ERP), τις διαφορές δυναμικού που μετρούμε, συνήθως στη δερματική επιφάνεια του κεφαλιού, οι οποίες προκαλούνται ως απόκριση σε συγκεκριμένο γεγονός, το οποίο συμβαίνει είτε στον εξωτερικό φυσικό κόσμο, είτε λαμβάνει χώρα ως ψυχολογική διαδικασία. Τα διακρίνουμε σε Εκπεμπόμενα Δυναμικά (Emitted Potentials) όταν σχετίζονται με μία ψυχολογική διαδικασία και σε Προκλητά Δυναμικά - ΠΔ (Evoked Potentials - EP), όταν το ερέθισμα, το γεγονός, προέρχεται από τον εξωτερικό κόσμο. Ανάλογα με το είδος του εξωτερικού ερεθίσματος που τα προκαλεί τα Π.Δ διακρίνονται στις ακόλουθες κατηγορίες: [4]

1. Οπτικά προκλητά δυναμικά (Visual Evoked Potentials-VEP): Τα δυναμικά αυτά προκαλούνται από οπτικό ερεθισμό, όπως εμφάνιση μιας συγκεκριμένης εικόνας, αλλαγή χρωμάτων, λάμπεις κ.ά.
2. Ακουστικά προκλητά δυναμικά (Auditory Evoked Potentials-AEP) Τα δυναμικά αυτά προκαλούνται από ακουστικό ερεθισμό, π.χ. ήχους, λέξεις, τόνους διαφόρων συχνοτήτων και έντασης.
3. Σωματοαισθητικά προκλητά δυναμικά (Somatosensory Evoked Potentials): Τα δυναμικά αυτά προκαλούνται όταν ένα μικρής διάρκειας και έντασης ηλεκτρικό ρεύμα ερεθίσει κάποιο συγκεκριμένο νεύρο.

Τα ΠΔ μπορούν επίσης να κατηγοριοποιηθούν με βάση τον χρόνο εμφάνισης τους μετά το ερέθισμα, ο οποίος ονομάζεται λανθάνων χρόνος εμφάνισης τους. Στην περίπτωση των ακουστικών προκλητών δυναμικών υπάρχει η ακόλουθη διάκριση [5]:

1. Πρώιμα δυναμικά (early, fast): Τα δυναμικά αυτά αντιστοιχούν σε χρονικά διαστήματα 2 έως 12ms από την στιγμή που χορηγείται ο εξωτερικός ερεθισμός και χαρακτηρίζονται σε πλάτη της τάξης του 0.1 έως 0.5μV και συχνότητα 100 έως 1000Hz. Τα πρώιμα δυναμικά σχετίζονται με την διαβίβαση των νευρωνικών ώσεων κατά μήκος του ακουστικού ή του οπτικού νεύρου.
2. Μέσα δυναμικά (middle): Τα δυναμικά αυτά σχετίζονται με χρονικά διαστήματα από 12 έως 50ms από την στιγμή που χορηγείται ο εξωτερικός ερεθισμός.

3. Ύστερα δυναμικά (late): Τα δυναμικά αυτά σχετίζονται με χρονικά διαστήματα 50 έως 800ms από την στιγμή που χορηγείται ο εξωτερικός ερεθισμός και χαρακτηρίζονται από πλάτη 1 έως 20μV και συχνότητες 0.1Hz έως 5 Hz. Τα δυναμικά αυτά αντανακλούν την εγκεφαλική δραστηριότητα περιοχών του φλοιού ως αντίδραση της άφιξης της εξωτερικής πληροφορίας.

Μια τελευταία κατηγοριοποίηση των ΠΔ τα διαχωρίζει σε ενδογενή και εξωγενή. Τα εξωγενή σχετίζονται άμεσα με την φύση του εκλυτικού ερεθίσματος δηλαδή την ένταση, την συχνότητα του και την ακεραιότητα των αισθητικών οδών. Αντίθετα τα ενδογενή ΠΔ εξαρτώνται ουσιαστικά από την ψυχολογική κατάσταση του ατόμου και από τα ψυχολογικά γνωρίσματα του απλού ή σύμπλοκου ερεθίσματος δηλαδή αν το ερέθισμα είναι γνωστό ή άγνωστο, αν προκαλεί δυσφορία ή ευχαρίστηση, αν είναι σημασιολογικά ορθό ή λάθος, ενδιαφέρον ή αδιάφορο κ.τ.λ. Ο λανθάνων χρόνος εμφάνισης των ενδογενών δυναμικών βρίσκεται συνήθως ανάμεσα στα 100 με 500ms.

Η μελέτη των κυματομορφών ΠΔ διεξάγεται στηριζόμενη κυρίως στα λεγόμενα συστατικά (components) του βιοματικού κύματος δυναμικού. Τα συστατικά είναι μερικές κυματομορφές του βασικού σήματος, δηλαδή τμήματά του, τα οποία καθορίζονται βάση κορυφώσεων (αρνητικών ή θετικών) του πλάτους δυναμικού, της χρονικής στιγμής στην οποία κατά προσέγγιση λαμβάνει χώρα η κορύφωση και του χρονικού εύρους το οποίο καταλαμβάνει η μερική κυματομορφή που περιέχει την συγκεκριμένη κορύφωση. Το πλάτος του συστατικού μετρείται με βάση την ισοηλεκτρική γραμμή των 0V ή το επίπεδο δυναμικού στην έναρξη της διαδικασίας μέτρησης ή κάποια άλλη προγενέστερη κορύφωση. Οι χρόνοι, αντίστοιχα, εκφράζονται συνήθως με αρχή την χρονική στιγμή που λαμβάνει χώρα το εκλυτικό γεγονός του συνολικού ΠΔ [4]. Τα ΠΔ, ως μετρήσιμες ποσότητες που εξάγονται κάτω από αυστηρά ελεγχόμενες πειραματικές συνθήκες προσφέρονται ως σημαντικός παράγοντας στην προώθηση της ψυχιατρικής έρευνας και κλινικής εφαρμογής, τόσο στις διαγνωστικές διαδικασίες όσο και στην ψυχοφαρμακολογία.

Chapter 3

Τεχνητή νοημοσύνη και Νευρωνικά δίκτυα

3.1 Πεδία της τεχνητής νοημοσύνης

3.1.1 Τεχνητή νοημοσύνη

Η Τεχνητή Νοημοσύνη αποτελεί ένα εργαλείο για την επίλυση προβλημάτων, μέσω του συνδυασμού Computer Science και δεδομένων. Η Μηχανική Μάθηση (Machine Learning) και Βαθιά Μάθηση (Deep Learning) αποτελούν τα δύο κυριότερα υπο-πεδία της Τεχνητής Νοημοσύνης. Αυτοί οι δύο υπο-κλάδοι καταφέρνουν μέσα από AI αλγορίθμους να σχεδιάσουν συστήματα είτε πρόβλεψης (prediction systems) είτε κατηγοριοποίησης (classification systems). Η Τεχνητή Νοημοσύνη είναι ένα πεδίο στην Επιστήμη των Υπολογιστών, το οποίο με την πάροδο του χρόνου αποκτά ολοένα και μεγαλύτερο ενδιαφέρον, με αποτέλεσμα ολοένα και περισσότεροι ερευνητές να ασχολούνται με αυτή. (σχήμα [3.1](#))

Η μηχανική και η βαθιά μάθηση χωρίζονται σε τρεις κατηγορίες ανάλογα με τη φύση και τον στόχο του εκάστοτε προβλήματος. Σημειώνεται ότι οι κατηγορίες αυτές είναι, σε μεγάλο βαθμό, συνυφασμένες με τους τρόπους με τους οποίους μαθαίνει ο άνθρωπος. Οι τρεις κατηγορίες είναι οι εξής:

- Επιβλεπόμενη μάθηση (Supervised Learning): οι αλγόριθμοι κατασκευάζουν μια συνάρτηση απεικόνισης των δεδομένων εισόδου του συνόλου εκπαίδευσης με τις γνωστές εξόδους τους, με σκοπό την όσο το δυνατόν πιο επιτυχημένη γενίκευση της συνάρτησης αυτής, έτσι ώστε να προβλέπονται για νέα δεδομένα εισόδου τα επιθυμητά, αλλά

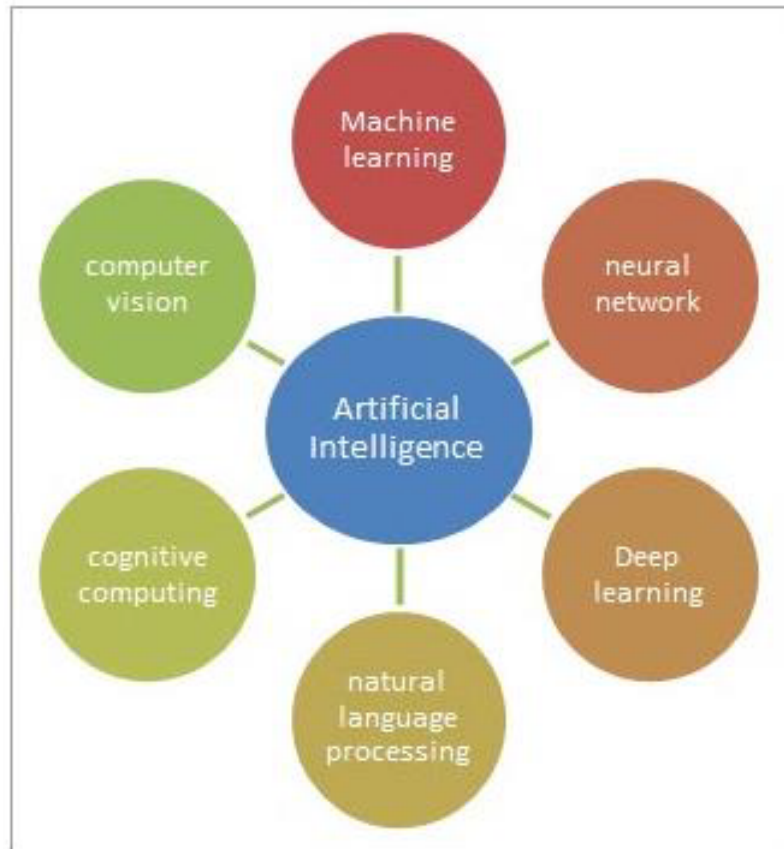


Figure 3.1: Πεδία της τεχνητής νοημοσύνης

άγνωστα αποτελέσματά τους. Συνεπώς, για την εκπαίδευση απαιτούνται δεδομένα με επισημασμένες τις σωστές απαντήσεις τους (δράση του ανθρώπινου παράγοντα). Αυτού του είδους η μάθηση συναντάται σε προβλήματα ταξινόμησης, πρόβλεψης και διερμηνείας.

- Μη επιβλεπόμενη μάθηση (Unsupervised Learning): οι αλγόριθμοι, βάσει των δεδομένων εισόδου, κατασκευάζουν μοντέλα μέσω των οποίων εντοπίζονται συσχετίσεις και δημιουργούνται ομάδες δεδομένων με σκοπό την επίλυση του προβλήματος χωρίς τη χρήση εμπειρίας κι άρα κάποιας καθοδήγησης. Συνεπώς, για την εκπαίδευση δεν απαιτούνται δεδομένα στα οποία έχουν επισημανθεί τα σωστά αποτελέσματα. Αυτού του είδους η μάθηση συναντάται σε προβλήματα, όπως ανάλυσης συσχετισμών και ομαδοποίησης
- Ενισχυτική Μάθηση (Reinforcement Learning): οι αλγόριθμοι μαθαίνουν μια στρατηγική ενεργειών μέσα από την αλληλεπίδραση τους με ένα δυναμικό περιβάλλον στο οποίο πρέπει να επιτευχθεί ένας συγκεκριμένος στόχος χωρίς να υπάρχουν ρητές οδη-

γίες. Αυτού του είδους η μάθηση συναντάται σε προβλήματα σχεδιασμού, όπως για παράδειγμα ο έλεγχος κίνησης ρομπότ, η οδήγηση ενός οχήματος, η βελτιστοποίηση εργασιών σε εργοστασιακούς χώρους και η αντιμετώπιση των αντιπάλων σε ηλεκτρονικά παιχνίδια. [10]

3.1.2 Μηχανική μάθηση (Machine Learning)

Ο όρος «μηχανική μάθηση» περιγράφει τον κλάδο της τεχνητής νοημοσύνης που ασχολείται με την επιστημονική μελέτη αλγορίθμων και στατιστικών μοντέλων που χρησιμοποιούνται από τα υπολογιστικά συστήματα, με σκοπό την εκτέλεση και βελτίωση μιας εργασίας με τη χρήση της εμπειρίας τους. Το 1959, ο Arthur Samuel ορίζει τη μηχανική μάθηση ως «Πεδίο μελέτης που δίνει στους υπολογιστές την ικανότητα να μαθαίνουν, χωρίς να έχουν ρητά προγραμματιστεί», ενώ το 1997, ο Tom Mitchell αναφέρει ότι «Η μηχανική μάθηση είναι η μελέτη των αλγορίθμων που επιτρέπουν στα προγράμματα υπολογιστών να βελτιώνονται αυτόματα μέσω της εμπειρίας». Οι αλγόριθμοι μηχανικής μάθησης δημιουργούν μαθηματικά μοντέλα και πρότυπα από ένα σύνολο δεδομένων πάνω στο οποίο εκπαιδεύονται και έχουν ως στόχο την πρόβλεψη συμπεριφορών ή τη λήψη αποφάσεων βασιζόμενοι στην εκμάθησή τους. Πιο συγκεκριμένα, κατασκευάζουν μοντέλα από πειραματικά δεδομένα και βασιζόμενοι σε αυτά εξάγουν το τελικό αποτέλεσμα που συνιστά μια πρόβλεψη ή μία απόφαση. [11]

Τα προβλήματα της μηχανικής μάθησης χωρίζονται σε υποκατηγορίες ανάλογα με το είδος της πρόβλεψης που χρειάζεται να κάνουμε, δηλαδή ανάλογα με το αποτέλεσμα που επιθυμούμε να λάβουμε. Έτσι, έχουμε τα ακόλουθα είδη προβλημάτων:

- Ταξινόμησης (Classification): όταν τα δεδομένα εισόδου χωρίζονται σε δύο ή περισσότερες κλάσεις, στις οποίες το μοντέλο που εκπαιδεύεται πρέπει να τα αντιστοιχίσει σωστά. Ως έξοδος προβλέπεται μία διακριτή τιμή ως ταμπέλα μιας από τις κλάσεις του προβλήματος. Αυτού του είδους τα προβλήματα είναι χαρακτηριστικά της επιβλεπόμενης μάθησης.
- Παλινδρόμησης (Regression): όταν το εκπαιδευμένο μοντέλο προβλέπει στην έξοδο του συνεχείς αριθμητικές τιμές. Αυτού του είδους τα προβλήματα είναι, επίσης, χαρακτηριστικά της επιβλεπόμενης μάθησης.
- Συσταδοποίησης (Clustering): όταν το σύνολο δεδομένων πρέπει να χωριστεί σε ομά-

δες, οι οποίες, όμως, σε αντίθεση με τα προβλήματα ταξινόμησης δεν είναι γνωστές, αλλά δημιουργούνται κατά την εκπαίδευση του μοντέλου. Αυτού του είδους τα προβλήματα είναι χαρακτηριστικά της μη επιβλεπόμενης μάθησης.

3.1.3 Βαθιά μάθηση (Deep Learning)

Η Βαθιά Μάθηση προσπαθεί να μιμηθεί τον τρόπο με τον οποίο λειτουργεί ο ανθρώπινος εγκέφαλος. Αυτό το πετυχαίνει με τη δημιουργία και χρήση νευρωνικών δικτύων (neural networks) αξιοποιώντας και συνδυάζοντας δεδομένα εισόδου (input data), βάρη (weights) και της προκατάληψης (bias), προκειμένου να αναγνωρίσει με ακρίβεια, να ορίσει την τάξη (classify) και να περιγράψει αντικείμενα στα δεδομένα. Τα Βαθιά Νευρωνικά Δίκτυα (Deep Neural Networks-DNN) αποτελούνται από πολλαπλά στρώματα (layers), τα οποία με τη σειρά τους αποτελούνται από ένα σύνολο διασυνδεδεμένων κόμβων (σχήμα [3.2](#)).




Figure 3.2: Σχηματική αναπαράσταση βαθιού νευρωνικού δικτύου

Το καθένα από αυτά τα στρώματα βασίζεται στο προηγούμενο επίπεδο για να βελτιώσει και να βελτιστοποιήσει την πρόβλεψη ή την κατηγοριοποίηση. Η εκτέλεση υπολογισμών από τα αρχικά στρώματα προς τα τελικά στρώματα στο Βαθύ Νευρωνικό Δίκτυο ονομάζεται forward propagation. Το forward propagation είναι η διαδικασία με την οποία εξάγονται τα επιθυμητά αποτελέσματα. Το στρώμα εισόδου (input layer) και το στρώμα εξόδου (output layer) ονομάζονται ορατά στρώματα (visible layers). Το στρώμα εισόδου είναι το πρώτο στρώμα του Μοντέλου Βαθιάς Μάθησης και σε αυτό εισάγονται τα δεδομένα που θα υποστούν επεξεργασία. Το στρώμα εξόδου αποτελεί το τελευταίο στρώμα και σε αυτό γίνεται η πρόβλεψη ή η κατηγοριοποίηση. Μια άλλη διαδικασία που ονομάζεται backpropagation

, χρησιμοποιεί αλγορίθμους όπως gradient descent (απότομης καθόδου) για να υπολογίσει τα σφάλματα στις προβλέψεις και έπειτα προσαρμόζει τα weights και biases πηγαίνοντας από τα πίσω στρώματα προς τα μπρος. Αποτέλεσμα αυτής της διαδικασίας είναι σταδιακά το μοντέλο να εκπαιδεύεται, να ελαχιστοποιεί τα σφάλματα και να πετυχαίνει μεγαλύτερη ακρίβεια. [12]

3.2 Χαρακτηριστικά Νευρωνικών Δικτύων

Τα νευρωνικά δίκτυα είναι ένα υπολογιστικό μοντέλο, εμπνευσμένο από το νευρολογικό σύστημα βιολογικών οργανισμών, που αποτελεί μια απλουστευμένη προσομοίωση της δραστηριότητας του εγκεφάλου. Βασικό δομικό στοιχείο στις περισσότερες αρχιτεκτονικές αποτελεί ο νευρώνας, μια μονάδα υπολογισμού που δέχεται εισόδους τις οποίες επεξεργάζεται για να παράγει μια έξοδο. Ομάδες τέτοιων νευρώνων μπορούν να χρησιμοποιηθούν για την κατασκευή ενός επιπέδου, στο οποίο όλοι οι νευρώνες δέχονται τις ίδιες εισόδους και παράγουν διαφορετικές εξόδους. Θεωρώντας πολλά τέτοια επίπεδα στη σειρά, όπου οι εξοδοί ενός επιπέδου τίθενται ως εισοδοί στο επόμενο, μπορούμε να δημιουργήσουμε πολύπλοκες αρχιτεκτονικές που ονομάζονται πολυεπίπεδα νευρωνικά δίκτυα. Αν ο αριθμός των επιπέδων είναι μεγάλος τότε μιλάμε για βαθιά νευρωνικά δίκτυα [11]. Με βάση τον τρόπο που οι νευρώνες συνδέονται μεταξύ τους στα κρυφά τους στρώματα, τα βαθιά νευρωνικά δίκτυα μπορούν να χωριστούν στις εξής βασικές κατηγορίες:

- Fully-connected/dense layer: Είναι το πιο απλό είδος στρώματος, στο οποίο όλοι οι νευρώνες του συνδέονται με σύναψη με κάθε νευρώνα του προηγούμενου στρώματος.
- Συνελικτικά Νευρωνικά Δίκτυα (CNN): Επιτελούν στα κρυφά τους στρώματα συνελίξεις και χρησιμοποιούνται κυρίως στην ανάλυση εικόνας. Κάθε συνελικτικό στρώμα που λαμβάνει την είσοδό του από το προηγούμενο στρώμα την συνελίσσει με ένα πλήθος από φίλτρα συγκεκριμένων διαστάσεων και παράγει πολλαπλά κανάλια εξόδου, όσα και τα φίλτρα. Επίσης, τα CNN μπορεί να συνοδεύονται και από άλλα στρώματα πέραν των συνελικτικών, όπως στρώματα pooling, normalization ή fully-connected.
- Επαναλαμβανόμενα Νευρωνικά Δίκτυα (RNN): Τα επαναλαμβανόμενα νευρωνικά δίκτυα (RNN) αποτελούν μια κλάση νευρωνικών δικτύων όπου οι συνάψεις μεταξύ των νευρώνων σχηματίζουν έναν ισχυρά συνεκτικό γράφο, που σημαίνει ότι υπάρχει μονο-

πάτι από κάθε νευρώνα σε κάθε άλλο. Αυτό σημαίνει ότι το RNN μπορεί να διατηρήσει κάποιες μορφές μνήμη και να τη χρησιμοποιήσει προκειμένου να εξαγάγει χρονικές πληροφορίες πάνω στην είσοδο. Τα RNN χρησιμοποιούνται κυρίως στην αναγνώριση ομιλίας ή γραφικού χαρακτήρα, αλλά μπορούν να φανούν χρήσιμα σε κάθε εφαρμογή με χρονικά συσχετιζόμενες εισόδους.

3.2.1 Τεχνητός Νευρώνας Perceptron

Ο τεχνητός νευρώνας (artificial neuron) γνωστός με την ονομασία αντίληπτρο (perceptron) αποτελεί την βασική δομική μονάδα της μεγάλης οικογένειας των προσθιοδρομικών νευρωνικών δικτύων (feed-forward neural networks). Το perceptron προτάθηκε ως ένας δυαδικός ταξινομητής [13]. Στην γενικότερη περίπτωση, ανάλογα με την συνάρτηση ενεργοποίησής του, μπορεί να χρησιμοποιηθεί για δυαδική ταξινόμηση, γραμμική ή και μη γραμμική παλινδρόμηση. Συνήθως ένας perceptron έχει n εισόδους και μία έξοδο. Κάθε μία από αυτές τις εισόδους πολλαπλασιάζεται με την συνιστώσα του βάρους στο οποίο αντιστοιχεί και το άθροισμά τους, το οποίο ουσιαστικά αποτελεί το εσωτερικό γινόμενο του διανύσματος εισόδου με το διάνυσμα των βαρών, μετασχηματίζεται μέσω της βηματικής συνάρτησης ενεργοποίησης αφού προστεθεί πρώτα σε αυτό μία σταθερά γνωστή ως προκατάληψη (bias). (σχημα [3.3](#))




Figure 3.3: Σχηματική αναπαράσταση perceptron

Έτσι προκύπτει η έξοδος του perceptron: (συναρτηση [3.1](#))

$$y = g\left(\sum_{i=0}^n x_i w_i + b\right) \quad (3.1)$$

Όπου:

- y : έξοδος νευρώνα perceptron
- g : συνάρτηση ενεργοποίησης
- x_i : συνιστώσα διανύσματος εισόδου
- w_i : συνιστώσα διανύσματος βαρών
- b : προκατάληψη (bias)

3.2.2 Συναρτήσεις Ενεργοποίησης

Στην γενική περίπτωση, το εσωτερικό γινόμενο των διανυσμάτων της εισόδου και των βαρών ενός perceptron (έστω input) μετασχηματίζεται μέσω μιας συνάρτησης πριν αυτό φτάσει στην έξοδο και τροφοδοτήσει τα επόμενα επίπεδα νευρώνων. Η συνάρτηση αυτή καλείται συνάρτηση ενεργοποίησης (activation function). Οι συναρτήσεις αυτές διαδραματίζουν πρωτεύοντα ρόλο στην συνολική επίδοση ενός ΤΝΔ. Οι βασικότερες συναρτήσεις με βάση την βιβλιογραφία καθώς και τα διαγράμματα τους παρατίθενται στη συνέχεια. [14] (σχήμα 3.4)

- Ταυτοτική Συνάρτηση (Identity Function): απεικονίζει την είσοδο στην έξοδο χωρίς κανένα ενδιάμεσο μετασχηματισμό.
- Βηματική Συνάρτηση (Step Function): προσομοιάζει περισσότερο την δομή και λειτουργία των φυσικών νευρώνων του εγκεφάλου οι οποίοι είτε πυροδοτούνται, είτε όχι.
- Ανορθωμένη Γραμμική Συνάρτηση (Rectified Linear Unit): ή ReLU συνήθως χρησιμοποιείται όταν θέλουμε να έχουμε αποτελέσματα παραπλήσια με αυτά της βηματικής συνάρτησης, αλλά παράλληλα επιθυμούμε να μεταδίδεται το μέγεθος των χαρακτηριστικών μεταξύ των στρώσεων του νευρωνικού δικτύου.
- Κανονικοποιημένη Εκθετική Συνάρτηση (Normalized Exponential Function): γνωστή ως softmax, αποτελεί την συνήθη επιλογή όταν στην έξοδο ενός νευρωνικού δικτύου θέλουμε να εκφράσουμε πιθανότητες. Δηλαδή, όταν θέλουμε όλες οι έξοδοι να αθροίζονται στην μονάδα, πράγμα ιδιαίτερα χρήσιμο σε προβλήματα ταξινόμησης.
- Υπερβολική εφαπτομένη (tanh) και Σιγμοειδής (sigmoid): Μια ιστορικά δημοφιλής οικογένεια συναρτήσεων ενεργοποίησης είναι οι υπερβολικές και λογιστικές συναρτήσεις με κύρια παραδείγματα την υπερβολική εφαπτομένη και τη σιγμοειδή: Η σιγμο-

ειδής και η υπερβολική εφαπτομένη περιορίζουν την είσοδό τους στα διαστήματα $[0, 1]$, $[-1, 1]$ αντίστοιχα, ενώ οι κλίση τους περιορίζεται στο $[0, 1]$.




Figure 3.4: Βασικότερες συναρτήσεις ενεργοποίησης

3.2.3 Συνάρτηση Λάθους

Η εκπαίδευση ενός νευρωνικού δικτύου συνίσταται στην εύρεση των συναπτικών βαρών και πολώσεων των νευρώνων προς την επίτευξη της επιθυμητής εξόδου για κάθε παράδειγμα του συνόλου δεδομένων. Προς αυτό το σκοπό, πρέπει να οριστεί μια μετρική της απόστασης μεταξύ της επιθυμητής εξόδου και της πραγματικής εξόδου του μοντέλου. Δεδομένης της απόστασης αυτής, η διαδικασία εκπαίδευσης συνίσταται στην ελαχιστοποίηση της απόστασης αυτής για το σύνολο δεδομένων. Η μετρική αυτή ονομάζεται συνάρτηση λάθους και ο ορισμός της εξαρτάται από τα δεδομένα του προβλήματος. Ένα διαδεδομένο πρόβλημα μηχανικής μάθησης είναι το πρόβλημα της ταξινόμησης. Σε αυτό καλούμαστε να μοντελοποιήσουμε μια συνάρτηση που ταξινομεί τα δεδομένα σε επιθυμητές κλάσεις. Η πιο διαδεδομένη προσέγγιση επίλυσης τέτοιων προβλημάτων περιλαμβάνει την μοντελοποίηση, μέσω του νευρωνικού δικτύου, μιας κατανομής πιθανότητας \hat{y} που εκφράζει την πιθανότητα ένα παράδειγμα να ανήκει σε μια συγκεκριμένη κλάση. Η συνάρτηση λάθους για το παράδειγμα j μπορεί να εκφραστεί με το cross-entropy για c κλάσεις: (συναρτηση [3.2](#))

$$L_j = - \sum_{i=1}^c y_i^j \log \hat{y}_i^j \quad (3.2)$$

Συχνά, αντί για την παρουσίαση όλων των παραδειγμάτων του συνόλου εκπαίδευσης για τον υπολογισμό της συνάρτησης κόστους, επιλέγεται η προσέγγιση της συνάρτησης κόστους μέσω του μέσου λάθους για ένα μέρος του συνόλου εκπαίδευσης. Η διαδικασία αυτή ονομάζεται Batch Gradient Descent και επιτυγχάνει ένα trade-off μεταξύ ταχύτητας εκπαίδευσης και ακρίβειας στην προσέγγιση της συνάρτησης κόστους, καθώς κάνουμε updates με μικρότερο υπολογιστικό κόστος αλλά εισάγοντας λάθη στη προσέγγιση της συνάρτησης κόστους. Μια εποχή του Batch Gradient Descent αποτελείται από διαχωρισμό του συνόλου δεδομένων σε ένα πλήθος mini-batches και διαδοχικά updates των παραμέτρων του δικτύου για κάθε batch. [15]

3.2.4 Στοιχεία Συνελκτικού Νευρωνικού Δικτύου(CNN)

Τα CNNs βρίσκουν εφαρμογή στην αναγνώριση εικόνων και βίντεο, την κατηγοριοποίηση εικόνας, την ανάλυση ιατρικών εικόνων, τις χρονοσειρές και την επεξεργασία φυσικής γλώσσας. Όπως δηλώνει και το όνομα τους, βασίζονται στη μαθηματική διαδικασία της συνέλιξης. Η είσοδος της συνέλιξης είναι είτε ακατέργαστα δεδομένα, είτε κάποιος χάρτης χαρακτηριστικών που προέρχεται από προηγούμενα επίπεδα CNNs. Ένα φίλτρο, ο λεγόμενος πυρήνας «σαρώνει» κατά πλάτος και κατά ύψος(αν είναι δύο διαστάσεων) τα δεδομένα εισόδου και παράγει χαρακτηριστικά μέσα από τη συνέλιξη. Συγκεκριμένα, η είσοδος περνάει από διαδοχικά επίπεδα επεξεργασίας, προκειμένου να εξαχθεί η τελική πρόβλεψη του δικτύου. Η διαδικασία αυτή είναι σειριακή, και ακολουθείται από μία άλλη διαδικασία, για την εκπαίδευση του δικτύου, την οπισθοδιάδοση(backpropagation) σφάλματος. [11]

Το συνελκτικό επίπεδο χρησιμοποιεί ένα σύνολο από φίλτρα τα οποία εντοπίζουν την παρουσία συγκεκριμένων χαρακτηριστικών ή μοτίβων που παρουσιάζονται στα δεδομένα εισόδου. Το κάθε φίλτρο «σαρώνει» κατά πλάτος και κατά ύψος την είσοδο και με τη μέθοδο της συνέλιξης δημιουργεί διαδοχικά ένα νέο πίνακα που ονομάζεται χάρτης χαρακτηριστικών (feature map). Η έξοδος του επιπέδου αυτού καθορίζεται από το μέγεθος του κάθε φίλτρου, το πλήθος των φίλτρων, το βήμα και το padding.

Το επίπεδο υποδειγματοληψίας (pooling layer) χρησιμοποιείται για τη μείωση της διάστασης του χάρτη χαρακτηριστικών. Αυτό εξυπηρετεί στην μείωση της ακρίβειας των χαρα-

κτηριστικών κι άρα της ευαισθησίας στις διαφορές μεταξύ των δειγμάτων, ώστε με κάποιον τρόπο να αποφευχθεί η υπερεκπαίδευση (overfit). Για αυτό το λόγο, στα περισσότερα CNNs ένα συνελκτικό επίπεδο ακολουθείται από ένα επίπεδο υποδειματοληψίας. Η υποδειματοληψία επιτυγχάνεται είτε με την επιλογή των μέγιστων τιμών του παραθύρου βάσει συνέλιξης με το φίλτρο (Max Pooling), είτε με τον υπολογισμό του μέσου όρου των τιμών του αντίστοιχου παραθύρου του πίνακα (Average Pooling).

Chapter 4

Σχεδίαση μοντέλου και προεπεξεργασία δεδομένων

4.1 Δεδομένα μοντέλου

Τα δεδομένα του μοντέλου που θα αναπτυχθεί στην παρούσα Διπλωματική εργασία προέρχονται από ένα πείραμα που διεξήχθη στο 401 Γενικό Στρατιωτικό Νοσοκομείο Αθηνών σε συνεργασία με το Εργαστήριο Βιοϊατρικής Οπτικής και Εφαρμοσμένης Βιοφυσικής του Εθνικού Μετσόβιου Πολυτεχνείου [16]. Εκεί πραγματοποιήθηκαν Ηλεκτροεγκεφαλικές καταγραφές με χρήση EEG σε 40 γιατρούς και νοσηλευτές του νοσοκομείου κατά την διάρκεια των οποίων εκτελούσαν μια σειρά από νοητικές διεργασίες. Πραγματοποιήθηκαν μετρήσεις στους συμμετέχοντες πριν και μετά την 48ωρη εφημερία τους, δηλαδή σε ξεκούραστη κατάσταση (rested) και σε κατάσταση στέρησης ύπνου (fatigued) .

4.1.1 N-Back

Λειτουργική μνήμη (ΛΜ) είναι ένας τύπος βραχυχρόνιας μνήμης που αποθηκεύει πληροφορίες προσωρινά κατά την ολοκλήρωση γνωστικών εργασιών, όπως η κατανόηση, η επίλυση προβλημάτων, ο συλλογισμός και η μάθηση. Η νοητική διεργασία που μας ενδιαφέρει για την παρούσα διπλωματική είναι μια χωροχρονική εργασία ΛΜ επονομαζόμενη N-back, η οποία μπορεί να προσεγγίσει τον χειρισμό φορτίων ΛΜ από τον εγκέφαλο. [17] Κατά την διάρκεια αυτής της εργασίας, οι συμμετέχοντες καλούνται να θυμηθούν την εικόνα που εμφανίζεται N φορές πριν και να την συγκρίνουν με την τρέχουσα εικόνα. Η διαδοχική φύση της εργασίας απαιτεί ταυτόχρονη γνωστική αποθήκευση και επεξεργασία των γνωστικών

διεργασιών, συμπεριλαμβανομένων των επιλογών, παρεμβολών και αναστολών που λαμβάνουν χώρα τη στιγμή που ένα οπτικό ερέθισμα κωδικοποιείται σχετικά με τη θέση και τον τύπο του, για να συγκριθεί στη συνέχεια με εκείνο που εμφανίζεται πίσω στην αλληλουχία.

Στη παρούσα έρευνα $N = 2$, δηλαδή ο συμμετέχων πρέπει να θυμηθεί και να συγκρίνει τις τελευταίες δύο εικόνες. Οι εικόνες εμφανίζονται στις τέσσερις γωνίες της οθόνης και υπάρχουν τέσσερις προϋποθέσεις τις οποίες ο συμμετέχων ζητείται να υποδείξει με το πάτημα του αντίστοιχου κουμπιού (Σχήμα 4.1):

1. Ίδια εικόνα και ίδια θέση.
2. Ίδια εικόνα (διαφορετική θέση).
3. Ίδια θέση (διαφορετική εικόνα).
4. Καμία ομοιότητα (διαφορετική εικόνα, διαφορετική θέση).




Figure 4.1: Παραδείγμα ακολουθείας οπτικών ερεθισμάτων της διεργασίας (σωστή ακολουθία απαντήσεων ξεκινώντας από την 3η εικόνα: 1,2,4,3)

Το πείραμα αυτό αποτελείται από 72 δοκιμασίες (4 ισορροπημένες συνθήκες) και διαρκεί περίπου 5 λεπτά. Τα οπτικά ερεθίσματα απεικονίζονται για 2,5 δευτερόλεπτα και στη συνέχεια ένας σταθερός σταυρός για 1 δευτερόλεπτο. Κάθε υπόδειξη του συμμετέχοντος καθώς και τα οπτικά ερεθίσματα καταγράφονται με τους κατάλληλους δείκτες.

4.1.2 Συλλογή δεδομένων

Για την ανάλυση των καταστάσεων νοητικής κόπωσης πραγματοποιούνται καταγραφές, οι οποίες αποθηκεύονται σε ψηφιακή μορφή και περιλαμβάνουν:

- Καταγραφές Ηλ/τος(HEΓ): Πραγματοποιούνται καταγραφές HEΓ υψηλής ανάλυσης από 64 κανάλια τοποθετημένα στο τριχωτό της κεφαλής σύμφωνα με το διεθνές σύστημα 10-20, με αναφορά στο μέσο όρο των καταγραφών στις μαστοειδείς αποφύσεις στα εσωτερικά των αυτιών (M1 και M2). Οι καταγραφές λαμβάνουν χώρα στο 401 Γενικό Στρατιωτικό Νοσοκομείο Αθηνών με χρήση του ηλεκτροεγκεφαλογράφου 64 καναλιών Biosemi ActiveTwo Mk2 with two-wire active electrodes του Εργαστήριου Βιοϊατρικής Οπτικής και Εφαρμοσμένης Βιοφυσικής του Εθνικού Μετσόβιου Πολυτεχνείου.
- Καταγραφές συμπεριφοράς: Οι καταγραφές συμπεριφοράς εξαρτώνται από την εκάστοτε εργασία. Στις εργασίες ΛΜ περιλαμβάνεται και η ορθότητα των απαντήσεων.

4.2 Προεπεξεργασία(preprocessing)

Όπως αναφέρθηκε και στο κεφάλαιο 2 το δυναμικό του εγκεφάλου στις καταγραφές του HEΓ είναι ιδιαίτερα ευαίσθητο σε διάφορες μορφές και πηγές θορύβου που παρουσιάζουν αρκετές προκλήσεις στην προσπάθεια ανάλυσης και ερμηνείας των ιδιοτήτων του σήματος, ιδίως όταν το σήμα είναι ένας συνδυασμός επιθυμητού δυναμικού του εγκεφάλου και θορύβου. Αυτές οι προσμειξίες του σήματος (artifacts) προέρχονται γενικά από μη εγκεφαλικές λειτουργίες και μπορεί να είναι αποτέλεσμα περιβαλλοντικών παραγόντων, εξοπλισμού ή βιολογικών πηγών. Έτσι, οι γραμμές εναλλασσόμενου ρεύματος, ο φωτισμός και μια μεγάλη σειρά ηλεκτρονικού εξοπλισμού (από υπολογιστές, κινητά τηλέφωνα κ.λπ.) παρουσιάζουν συνήθως έναν συστηματικό θόρυβο στα σήματα HEΓ, ο οποίος στη συνέχεια ενισχύεται μαζί με τα σήματα του φλοιού και έτσι ενσωματώνεται στα καταγεγραμμένα δεδομένα. Τα φυσιολογικά artifacts που δημιουργούνται από καρδιακά σήματα, μυϊκή συστολή και ανοιγοκλείσιμο των ματιών είναι μη συστηματικά και επομένως δεν μπορούν να προβλεφθούν ή να αποτραπούν [18].

4.2.1 Τεχνικές Διόρθωσης των artifacts

Για να αντιμετωπιστεί το ζήτημα της μόλυνσης του τεχνητού σήματος και, στη συνέχεια, να παρέχεται μια ισχυρή ανάλυση του ΗΕΓ, μπορούν να χρησιμοποιηθούν ορισμένα μέτρα κατά τη διάρκεια των διαδικασιών καταγραφής και, μετά την καταγραφή, ως βήματα προεπεξεργασίας. Στο πλαίσιο αυτό, η χρήση κλωβού Faraday, αγωγίμου περιβλήματος στα καλώδια, η χρήση λαμπτήρων φθορισμού και σωστά γειωμένων οργάνων απομονώνουν το δωμάτιο καταγραφής από τους περισσότερους περιβαλλοντικούς θορύβους, ενώ τα υποκείμενα που συμμετέχουν σε πειράματα ΗΕΓ συνήθως υποχρεούνται να ελαχιστοποιούν τις κινήσεις/ομιλίες τους και να διατηρούν τη βέλτιστη απόσταση από τον ηλεκτρονικό εξοπλισμό κατά τη διάρκεια των καταγραφών. [19] Οι παραπάνω ενέργειες λήφθηκαν υπόψη κατά τη διεξαγωγή των πειραμάτων που περιγράφονται στην παρούσα Διπλωματική Εργασία. Επιπλέον, για την αποτελεσματική αντιμετώπιση των μη συστηματικών artifacts, χρησιμοποιήθηκε ένας αριθμός στρατηγικών προεπεξεργασίας που περιλαμβάνει τα ακόλουθα βήματα για την απομάκρυνση του άσχετου θορύβου και τη διευκόλυνση της επακόλουθης ανάλυσης:

- Επαναδειγματοληψία(resampling): Αν και η υψηλή χρονική ανάλυση είναι γενικά επιθυμητή, έχει το μειονέκτημα ότι παρέχει μεγάλο όγκο δεδομένων, ο οποίος με τη σειρά του είναι πολύ πιο αργός κατά την επακόλουθη επεξεργασία. Στην παρούσα Διπλωματική Εργασία, τα δεδομένα υποδειγματοληπτήθηκαν με την εφαρμογή ενός φίλτρου anti-aliasing, λαμβάνοντας υπόψη τον κανόνα Nyquist για τον προσδιορισμό του βαθμού στον οποίο μπορεί να μειωθεί η συχνότητα δειγματοληψίας (δηλαδή, η συχνότητα δειγματοληψίας πρέπει να είναι τουλάχιστον διπλάσια από την υψηλότερη συχνότητα της ανάλυσης). [20]
- Re-referencing : Για να διαπιστωθεί ότι η ηλεκτρική δραστηριότητα δεν εξαρτάται από το σήμα αναφοράς, πραγματοποιήθηκε επαναυπολογισμός των τιμών των αισθητήρων κατά την ανάλυση των δεδομένων της παρούσας διπλωματικής, χρησιμοποιώντας μέση αναφορά ή μονοπολική αναφορά με βάση τα μαστοειδή ηλεκτρόδια [21]. Ως εκ τούτου, το νέο σήμα αναφοράς αφαιρέθηκε από κάθε κανάλι ΗΕΓ, οδηγώντας την τάση σε αυτά τα κανάλια να αντικατοπτρίζει τη διαφορά με το νέο σήμα αναφοράς, μειώνοντας τον συστηματικό θόρυβο του σήματος.
- Φιλτράρισμα: Κάθε σήμα αποτελείται από ημιτονοειδή και συνημιτονοειδή κύματα με διαφορετικές συχνότητες. Ένα ψηφιακό φίλτρο είναι ένας επεξεργαστής σήματος

που εξασθενεί επιλεκτικά ένα σήμα για κάθε μία από τις συχνότητες του. Οι συχνότητες της ζώνης διέλευσης του σήματος θα περάσουν αμετάβλητες από την είσοδο στην έξοδο, ενώ οι συχνότητες της ζώνης αποκοπής θα εξασθενήσουν πλήρως στην έξοδο του φίλτρου. Στις διαδικασίες φιλτραρίσματος προεπεξεργασίας των δεδομένων ΗΕΓ που χρησιμοποιήθηκαν στην παρούσα διατριβή, χρησιμοποιήθηκαν ζωνοπερατά φίλτρα πεπερασμένης απόκρισης παλμού (FIR) και χαμηλοπερατά και υψηλοπερατά φίλτρα Chebyshev άπειρης απόκρισης παλμού (IRR). [22]

Για το FIR φίλτρο τάξης N, η ακολουθία εξόδου υπολογίζεται ως εξής:

$$y[n] = \sum_{i=0}^N b_i x[n-i] \quad (4.1)$$

όπου N είναι η τάξη του φίλτρου, b_i η κρουστική απόκριση του φίλτρου, $x[n]$ το σήμα εισόδου και $y[n]$ το σήμα εξόδου.

Για το IIR φίλτρο το σήμα εξόδου υπολογίζεται ως εξής:

$$y[n] = \frac{1}{a_0} \left(\sum_{i=0}^P b_i x[n-i] - \sum_{j=1}^Q a_j y[n-j] \right) \quad (4.2)$$

Όπου P είναι η τάξη του feedforward φίλτρου, Q είναι η τάξη του φίλτρου ανατροφοδότησης (feedback), b_i είναι οι συντελεστές του feedforward φίλτρου, a_i οι συντελεστές του feedback φίλτρου και $x[n]$, $y[n]$ σήμα εισόδου και εξόδου αντίστοιχα.

Η συνάρτηση μεταφοράς του φίλτρου Chebyshev ορίζεται ως:

$$H(z) = \frac{b_1 + b_2 z^{-1} + \dots + b_{N+1} z^{-N}}{a_1 + a_2 z^{-1} + \dots + a_{N+1} z^{-N}} \quad (4.3)$$

Όπου z ο μετασχηματισμός-Z του διακριτού σήματος και N η τάξη του φίλτρου

- **De-trending:** Οι ροπές μπορούν να προκαλέσουν παραμόρφωση κατά την ανάλυση στα πεδία του χρόνου και της συχνότητας. Ως εκ τούτου, οι γραμμικές τάσεις μπορούν να υπολογιστούν (π.χ. μέσω της μεθόδου ελαχίστων τετραγώνων) και να αφαιρεθούν από τα δεδομένα. Στην παρούσα Διπλωματική Εργασία τα σήματα EEG αποτραβήχτηκαν με την εκτίμηση της γραμμής ελαχίστων τετραγώνων (που θεωρείται η καλύτερα προσαρμοσμένη) και την αφαίρεσή της από τα δεδομένα [23].

- Ανάλυση ανεξάρτητων συνιστωσών (ICA): Η ICA περιλαμβάνει το διαχωρισμό ενός πολυδιάστατου σήματος σε συνιστώσες, υποθέτοντας ότι τα σήματα είναι στατιστικά ανεξάρτητα μεταξύ τους. Στο πλαίσιο αυτό μπορούν να αφαιρεθούν ανεπιθύμητες συνιστώσες που αντιστοιχούν σε artifacts με βάση τα χαρακτηριστικά του σήματος (π.χ. συνιστώσες που συσχετίζονται σε μεγάλο βαθμό με σήματα EOG) [24]. Έτσι, η ICA μπορεί να διχωρίσει διαφορετικές πηγές σημάτων (όπως artifacts) υποθέτοντας έναν γραμμικό μείγμα μεταξύ των ανεξαρτήτων τυχαίων μεταβλητών. Συγκεκριμένα πολλαπλασιάζοντας τα έστω n ανεξάρτητα σήματα τυχαίας κατανομής με έναν $n \times n$ πίνακα “μίξης” και βρίσκοντας τις ιδιοτιμές και τα ιδιοδιανύσματα του πίνακα έτσι ώστε οι συνιστώσες να είναι ανεξάρτητες μεταξύ τους (δηλαδή covariance = 0) μπορούμε να εφαρμόσουμε τον αλγόριθμο ICA. Έτσι, για κάθε συνιστώσα w οι τιμές του αντίστροφου του πίνακα “μίξης” ανανεώνονται μέχρι ο αλγόριθμος να φτάσει σε σύγκλιση ή να ξεπεραστεί το όριο επαναλήψεων. Τελικά οι ανεξάρτητες συνιστώσες που προέρχονται από θόρυβο απορρίπτονται (με αυτόματες διαδικασίες ή μηχανικά) και το “καθαρό” σήμα υπολογίζεται από τον πίνακα “μίξης” θέτοντας μηδενικές στήλες για κάθε απορριπτέα συνιστώσα. (Σχήμα 4.2)

```

Step 1: Center X by subtracting the mean
Step 2: Whiten X
Step 3: Choose a random initial value for the de-mixing matrix W
Step 4: Calculate new value for W
Step 5: Normalize W
Step 5: Check if algorithm has converged; if not go to step 4
Step 6: Take the product of W and X to get the ICs

```

Figure 4.2: Βήματα μεθόδου Ανάλυσης ανεξάρτητων συνιστωσών

- Διόρθωση γραμμής αναφοράς: Η διόρθωση γραμμής αναφοράς (baseline) είναι μια γραμμική διαδικασία που χρησιμοποιείται για την εξάλειψη των μετατοπίσεων πλάτους ΗΕΓ πολύ χαμηλής συχνότητας τάσης (quasi-DC) που για ορισμένους λόγους μπορεί να εμφανιστούν μετά την εκδήλωση του διεγερτικού συμβάντος και εφαρμόζεται συνήθως όταν τα δεδομένα χωρίζονται σε διαφορετικές εποχές που σχετίζονται με το συμβάν. Στο πλαίσιο αυτό, σε κάθε τμηματοποίηση δεδομένων ΗΕΓ αφαιρείται από κάθε σημείο της κυματομορφής ο υπολογισμός του μέσου όρου των σημείων της λεγόμενης “baseline” περιόδου (που ποικίλλει σε κάθε πείραμα της παρούσας διατριβής) [25]. Παρόλο που η διόρθωση της γραμμής βάσης δεν θεωρείται ρητή διαδικασία διόρθωσης των artifacts, θεωρείται απαραίτητο βήμα προεπεξεργασίας για την

άμβλυνση των επιδράσεων offset, οι οποίες δεν αναμένεται να σχετίζονται με τους υπό διερεύνηση εγκεφαλικούς μηχανισμούς, για τη μετέπειτα ανάλυση.

4.2.2 Προεπεξεργασία δεδομένων πειράματος

Η καταγραφή του ΗΕΓ περιελάμβανε 64 ηλεκτρόδια Ag/AgCl στο τριχωτό της κεφαλής (μοντέλο: ASA Lab, ANT B. V., Ολλανδία), με θέσεις που αντιστοιχούσαν στο διεθνές σύστημα 10-20. Τα ακατέργαστα σήματα ψηφιοποιήθηκαν με συχνότητα δειγματοληψίας 256 Hz, ενώ η σύνθετη αντίσταση των ηλεκτροδίων διατηρήθηκε κάτω από 10 kΩ καθ' όλη τη διάρκεια των καταγραφών, ενώ τα ηλεκτροκυλόγραμμα μετρήθηκαν επιπλέον από κάθετα (πάνω και κάτω από το δεξί μάτι) και οριζόντια ηλεκτρόδια (τοποθετημένα στον εξωτερικό κώνθο). Η προεπεξεργασία περιελάμβανε ζωνοπερατό φίλτράρισμα (FIR 1 - 40 Hz), επαναφορά(re-referencing) του μέσου όρου σε σχέση με όλα τα ηλεκτρόδια και η αφαίρεση των artifacts πραγματοποιήθηκε με ICA, αφαιρώντας τις συνιστώσες που συσχετίζονταν σε μεγάλο βαθμό με τα οφθαλμικά σήματα [26]. Στη συνέχεια, τα δεδομένα ΗΕΓ αποκαταστάθηκαν, κατατιμήθηκαν σε (κλειδωμένες με το ερέθισμα) εποχές και διορθώθηκαν ως προς τη γραμμή βάσης σε σχέση με 100 ms πριν από την έναρξη του ερεθίσματος. Από τα δεδομένα που προέκυψαν, μόνο οι σωστές εποχές ενσωματώθηκαν για περαιτέρω ανάλυση. Η προεπεξεργασία υλοποιήθηκε με προσαρμοσμένους κώδικες στην βιβλιοθήκη EEGLAB στο MATLAB R2019b (The MathWorks Inc., ΗΠΑ). [27]

4.3 Σχεδιασμός μοντέλου

4.3.1 Δεδομένα εισόδου

Τα δεδομένα από το πείραμα, μετά από την προεπεξεργασία που περιγράφηκε παραπάνω, φορτώθηκαν από το EEGLAB μέσω της βιβλιοθήκης mne [28] σε περιβάλλον python με μορφή πίνακα με σκοπό την περαιτέρω επεξεργασία τους ώστε να χρησιμοποιηθούν ως είσοδος σε μοντέλο CNN. Ο πίνακας για κάθε μία από τις 40 μετρήσεις περιέχει ως στήλες τα 63 ηλεκτρόδια και ως γραμμές τα frames δηλαδή την χρονική στιγμή της μέτρησης (1 sec = 256 frames). Τα δεδομένα της διεργασίας N-back περιείχαν διαφορετικά labels στα frames που εμφανιζόταν στην οθόνη ένα ερέθισμα ανά 3 sec (1024 frames) και στα frames που κάθε συμμετέχοντας έδινε απάντηση ανεξαρτήτως αν ήταν σωστή ή όχι. Με την χρήση

αυτών των labels οι καταγραφές καθενός ατόμου χωρίστηκαν με βάση το σύνολο των 72 ερεθισμάτων στα 5 λεπτά που διήρκησε το πείραμα. Δηλαδή δημιουργήθηκαν για κάθε καταγραφή EEG 72 υποπίνακες με 1024 γραμμές(frames) και 63 στήλες(ηλεκτρόδια).(σχήμα 4.3) Στη συνέχεια, προστέθηκε ακόμα μια στήλη με δυαδικά στοιχεία που αντιπροσωπεύει την κατάσταση(state) του συμμετέχοντα όταν πραγματοποιήθηκε η καταγραφή ως εξής:

- “0” rested (πριν από εφημερία)
- “1” fatigued (μετά από εφημερία)

	Fp1	AF7	AF3	F1	F3	F5	F7	\
7943	-3.570607	1.484284	3.904389	-2.623775	0.080236	1.479535	15.181203	
7944	-2.392492	0.009420	6.231389	-2.313231	0.853243	1.470540	14.826508	
7945	-2.323218	-2.184662	7.539619	-1.899260	1.321660	2.088246	15.749866	
7946	-3.145959	-4.548862	7.091844	-1.957034	0.849889	2.310682	16.297350	
7947	-4.992455	-6.116075	5.031765	-3.017858	-0.406866	1.938884	15.135796	
	FT7	FC5	FC3	...	CP4	CP2	P2	\
7943	6.357632	-1.427643	-6.568274	...	0.007801	1.075608	1.377187	
7944	3.989550	-1.744801	-6.176887	...	-0.948626	1.306457	1.074608	
7945	5.563190	-2.126965	-5.873383	...	-0.980389	1.758711	0.969007	
7946	10.256593	-2.759326	-6.106049	...	-0.305139	1.936900	0.785809	
7947	14.817516	-2.808767	-6.304735	...	0.412237	1.918300	0.190689	
	P4	P6	P8	P10	P08	P04	O2	
7943	2.200600	6.751292	4.419022	15.137586	7.814332	5.205180	9.853456	
7944	0.470750	1.195095	2.054660	24.933941	6.502119	3.989095	9.822683	
7945	-0.916959	-2.277986	0.418876	22.278578	3.296826	2.497465	7.919456	
7946	-1.221695	0.978764	0.773135	8.147751	0.481682	1.149253	4.704763	
7947	-0.804775	9.143409	2.580461	-7.547260	-0.442267	0.287847	1.661918	

Figure 4.3: Παράδειγμα μορφής πίνακα καταγραφών (5 πρώτες γραμμές)

Έτσι, από τις 40 καταγραφές συνολικά δημιουργήθηκαν 2866 τέτοιοι πίνακες οι οποίοι χρησιμοποιούνται ως είσοδος σε συνελκτικό νευρωνικό δίκτυο (CNN) με σκοπό την κατηγοριοποίηση (classification) τους σε δύο σύνολα με βάση την στήλη ‘state’ του κάθε πίνακα. Για την σωστή εκπαίδευση του μοντέλου τα δεδομένα των πινάκων χωρίζονται τυχαία σε σύνολο εκπαίδευσης και σύνολο δοκιμής(train-test split) σε ποσοστό 75% και 25% αντίστοιχα. Το train split χρησιμοποιείται για την εκπαίδευση του μοντέλου που θα αναλυθεί παρακάτω και αποτελείται από 2149 πίνακες. Το test split χρειάζεται για την τελική πρόβλεψη σε άγνωστα για το μοντέλο δεδομένα που όμως περιέχουν ίσο αριθμό πινάκων σε κάθε κατηγορία και περιέχει 717 πίνακες. Οι αντίστοιχες στήλες ‘state’ του κάθε split χωρίζονται από τον κάθε πίνακα και αποτελούν τους δυαδικούς πίνακες trainlabel και testlabel με βάση τους οποίους το μοντέλο κατατάσσει τα δεδομένα.

4.3.2 Αρχιτεκτονική μοντέλου

Το μοντέλο που επιλέχθηκε για δυαδική κατηγοριοποίηση δεδομένων πίνακα δύο διαστάσεων βασίζεται σε ένα βαθύ νευρωνικό δίκτυο που τα δεδομένα περνάνε σειριακά (sequential) από στρώματα συνέλιξης μιας διάστασης και βοηθητικά στρώματα ως εξής:

1. Συνέλικτικό στρώμα μιας διαστασης (conv1D)
2. Dropout
3. Maxpooling1D
4. Flatten
5. Dense
6. Dense output layer

Οι κατάλληλες υπερπαραμέτροι των στρωμάτων βρέθηκαν μετά από αναζήτηση σε μορφή πλέγματος (gridsearch) συγκρίνοντας την ακρίβεια (accuracy) του αποτελέσματος του κάθε συνδυασμού υπερπαραμέτρων. Παράλληλα βρέθηκε ο βέλτιστος αριθμός εποχών που γίνεται η ανατροφοδότηση των βαρών του δικτύου ώστε να αποφευχθεί τόσο το overfit όσο και το underfit των δεδομένων του μοντέλου. Τέλος αφαιρέθηκε ο κατάλληλος αριθμός ηλεκτροδίων(στήλες), με βάση την τυπική απόκλιση των τιμών τους, χωρίς να έχει επίπτωση στα τελικά ακρίβεια του μοντέλου αυξάνοντας όμως την ταχύτητα εκπαίδευσής του αισθητά. Η εκπαίδευση και πρόβλεψη του μοντέλου επαναλήφθηκε 20 φορές με τυχαίο χωρισμό σε train-test split σε κάθε επανάληψη και βρέθηκε ο μέσος όρος της ακρίβειας των προβλέψεων. Η αρχιτεκτονική του μοντέλου, οι διαστάσεις των δεδομένων κάθε στρώματος και οι τιμές των παραμέτρων που προαναφέρθηκαν φαίνονται στις εικόνες: (σχημα [4.5](#), [4.4](#))

```
'n_experiments': 20,      # number of repetitions
'n_elects': 40,          #number of electrodes used
'n_epochs': 8,           # number of epochs trained
'n_batch_size': 32,      # size of batches to be trained
'n_filters': [256],     # size of filter for the convolution
'n_kernel': 5,           # kernel size for convolution
'n_pool_size': 4,        # maxpooling layer size
'n_dropout_rate': 0.2,   # % of data to drop in dropout layer
'n_activation': 'relu',  # type of activation function
'n_neurons': 2000        # number of neurons in dense layer
```

Figure 4.4: Τιμές υπερπαραμέτρων μοντέλου

Το μοντέλο αναπτύχθηκε με την βιβλιοθήκη keras-tensorflow σε περιβάλλον python3.

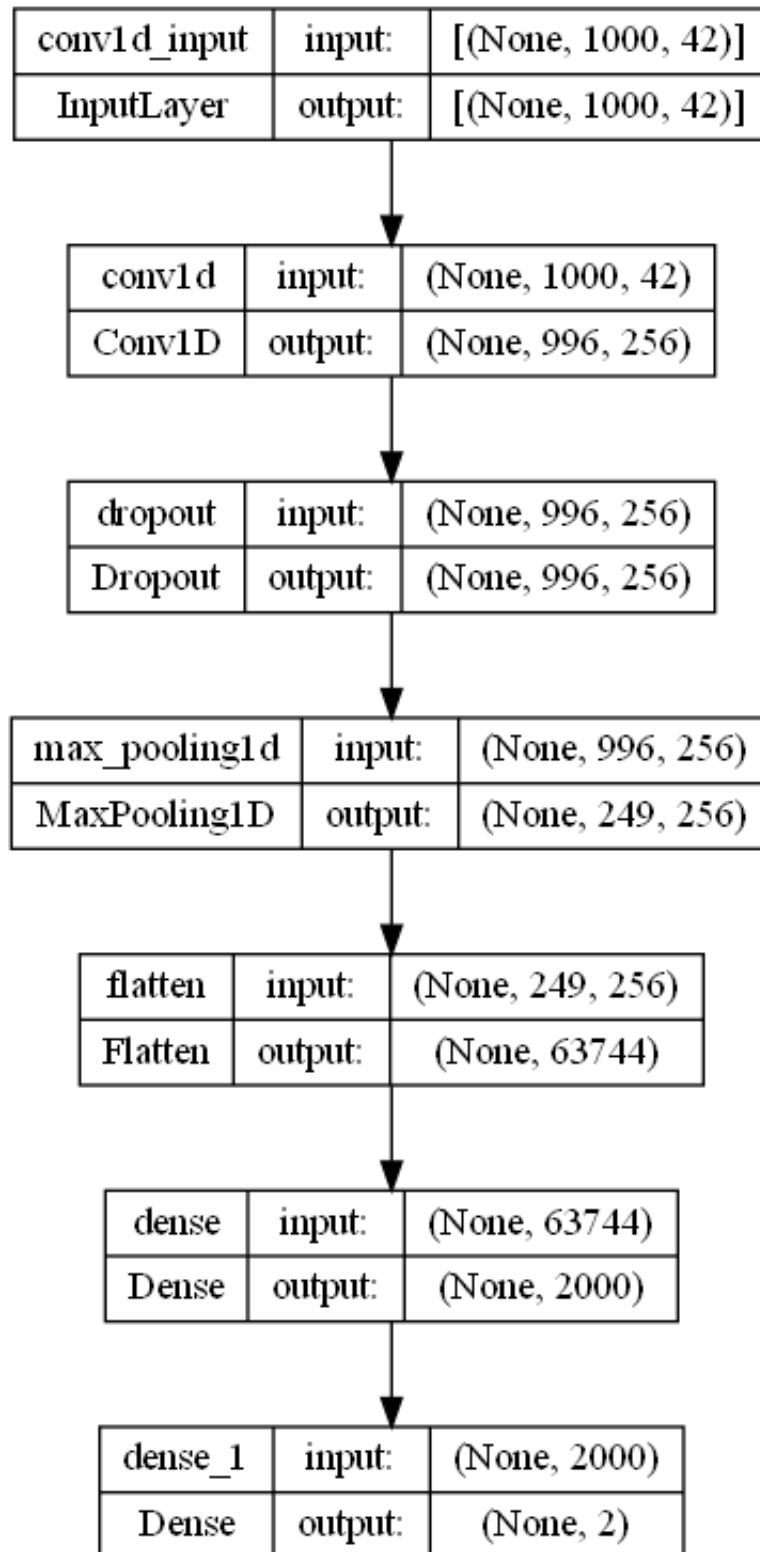


Figure 4.5: Model summary

Chapter 5

Αποτελέσματα

5.1 Αποτελέσματα




Figure 5.1: Διακύμανση της ακρίβειας των αποτελεσμάτων

Με την κατάλληλη επιλογή υπερπαραμέτρων το μοντέλο εκπαιδεύτηκε με το σύνολο εκπαίδευσης(train split) για 225 λεπτά (ή 3 ώρες και 45 λεπτά) και πρόβλεψε την κατάσταση(state) του συνόλου δοκιμής(test-split). Η μέση ακρίβεια του μοντέλου μετά από 20 επαναλήψεις είναι περίπου 86% με τυπική απόκλιση περίπου 3.5% όπως φαίνεται στην εικόνα (σχημα [5.1](#)) με μέγιστη ακρίβεια περίπου στο 90% και ελάχιστη στο 78%. Στις εικόνες (σχημα [5.2](#) [5.3](#)) παρουσιάζονται τα στατιστικά της εκπαίδευσης και ο πίνακας σύγκρισης




Figure 5.2: Πίνακας Σύγκρισης αποτελεσμάτων

```

classification report
precision    recall  f1-score   support

   0       0.90     0.82     0.86     358
   1       0.83     0.91     0.87     359

 accuracy          0.86     717
 macro avg         0.87     0.86     0.86     717
 weighted avg      0.87     0.86     0.86     717

```

Figure 5.3: Στατιστικά εκπαίδευσης μοντέλου

(confusion matrix) μιας μέσης πρόβλεψης του μοντέλου. Ο πλήρης κώδικας σε python παρουσιάζεται στο παραρτημα [A](#) της παρούσας διπλωματικής εργασίας.

Chapter 6

Παρατηρήσεις

6.1 Παρατηρήσεις

6.1.1 Διαφορετικές προσεγγίσεις

Μια διαφορετική προσέγγιση που εξερευνήθηκε για εκπαίδευση του μοντέλου πριν απορριφθεί ακολουθεί μια διαφορετική λογική στον διαχωρισμό των δεδομένων. Συγκεκριμένα, τα δεδομένα μετά από την προεπεξεργασία τους από το EEGLAB χωρίζονται ανά καταγραφή του ΗΕΓ αντί ανά απάντηση δηλαδή οι πίνακες που λαμβάνει ως είσοδο το μοντέλο περιέχουν πολύ περισσότερα frames (γραμμές) σε σχέση με το πρωτότυπο. Αυτό είχε ως αποτέλεσμα την μείωση του αριθμού των πινάκων τόσο κατά την εκπαίδευση του μοντέλου (από 2149 σε 30) όσο και κατά την πρόβλεψη (από 717 σε 10). Τελικά, παρατηρήθηκε υπερεκπαίδευση των δεδομένων λόγω μικρού δείγματος στα δεδομένα πρόβλεψης. Μια τέτοια στρατηγική θα μπορούσε να εφαρμοστεί αν υπήρχε μεγαλύτερος όγκος δεδομένων, δηλαδή καταγραφών ΗΕΓ, στο πείραμα από το οποίο αντλήθηκαν.

Μια ακόμα προσέγγιση του προβλήματος που αξίζει να αναφερθεί είναι η μέθοδος γνωστή ως Dynamic Time Wrapping (DTW) [29]. Αυτός ο αλγόριθμος χρησιμοποιείται για να μετρήσει την ομοιότητα μεταξύ σημάτων που μπορεί να διαφέρουν σε συχνότητα όπως τα σήματα των ηλεκτροδίων του ΗΕΓ. Έτσι, συγκρίνοντας τον συντελεστή ομοιότητας μεταξύ κάποιου σήματος αναφοράς από κάθε κλάση του προβλήματος (rested-fatigued) και των σημάτων της κάθε καταγραφής μπορεί να γίνει μια ταξινόμηση των σημάτων στις διαφορετικές κλάσεις. Ωστόσο, ο μεγάλος αριθμός ηλεκτροδίων δηλαδή οι διαστάσεις των σημάτων που πρέπει να συγκριθούν προκαλούν μεγάλη καθυστέρηση και ασαφή αποτελέσματα οπότε η

προσέγγιση απορρίφθηκε.

6.1.2 Διαχωρισμός απαντήσεων

Ο διαχωρισμός των σωστών με τις λάθος απαντήσεις των συμμετεχόντων στο πείραμα ανάλογα με την κατάστασή τους (state) όταν έγινε η μέτρηση είναι κάτι που μελετήθηκε κατά την εκπόνηση της παρούσας εργασίας. Συγκεκριμένα, βρέθηκε το ποσοστό των λάθος απαντήσεων σε κάθε κατάσταση για να διαπιστωθεί αν υπάρχει συσχέτιση μεταξύ της κούρασης των συμμετεχόντων και των απαντήσεων που δίνουν στο πείραμα. Τελικά, όσο αναφορά τα συγκεκριμένα δεδομένα από την διεργασία N-back το ποσοστό των λάθος απαντήσεων σε κατάσταση ξεκούρασης βρέθηκε μεγαλύτερο κατά περίπου 4.5% όπως φαίνεται στην εικόνα (σχήμα 5.3) σε σχέση με αυτό σε κατάσταση στέρησης ύπνου. Άρα, συμπεραίνεται ότι το είδος των απαντήσεων των συμμετεχόντων και η ενδεχόμενη απόρριψη δεδομένων με βάση αυτό δεν βοηθάει στην απλούστευση λύση του προβλήματος.

Chapter 7

Συμπεράσματα

7.1 Συμπεράσματα

Η ανίχνευση των επιπέδων κόπωσης ενός ατόμου μέσω των μετρήσεων των σημάτων του εγκεφάλου του είναι ένα ενδιαφέρον πεδίο έρευνας. Μια τέτοια πρακτική και συστηματική μέτρηση θα μπορούσε να βρει εφαρμογή σε όλους τους τομείς της εργασίας και να βελτιώσει δραστικά την απόδοση και ασφάλεια των εργαζομένων όλων των κλάδων. Για παράδειγμα θα μπορούσε να ανιχνευθεί αν κάποιος γιατρός είναι αρκετά ξεκούραστος για να μπορέσει να χειρουργήσει ή ένας οδηγός φορτηγού να συνεχίσει την οδήγηση. Το ΗΕΓ με την μορφή που έχει σήμερα και τα διάφορα σήματα θορύβου που μπορεί να καταγράφει, όπως έχει αναλυθεί στα προηγούμενα κεφάλαια, απαιτεί συγκεκριμένες συνθήκες και εξοπλισμό για να είναι τα αποτελέσματα του αξιόπιστα και για αυτό δεν είναι το ιδανικό εργαλείο για μια τέτοια εφαρμογή. Παρόλα αυτά, η παρούσα διπλωματική απέδειξε ότι, από τα δεδομένα του ΗΕΓ, είναι δυνατή η ανάπτυξη μοντέλου τεχνητής νοημοσύνης ικανού να κατατάξει με ικανοποιητική ακρίβεια τα επίπεδα κόπωσης κάποιου ατόμου με βάση την μέτρηση των σημάτων του εγκεφάλου του ενώ εκτελεί διεργασίες λειτουργικής μνήμης. Κλείνοντας, αξίζει να σημειωθεί ότι ο χρόνος εκπαίδευσης του μοντέλου εξαρτάται σε μεγάλο βαθμό από τις δυνατότητες του υπολογιστικού συστήματος στο οποίο εκτελείται κάτι που περιορίζει την περαιτέρω ανάπτυξη και δοκιμή διαφορετικών πιο σύνθετων αρχιτεκτονικών στο πλαίσιο της παρούσας εργασίας.

7.1.1 Μελλοντικές Προεκτάσεις

Το μοντέλο που αναπτύχθηκε στην παρούσα διπλωματική θα μπορούσε να ενσωματωθεί σε εφαρμογές διασύνδεσης εγκεφάλου-μηχανής όπως αυτή που έχει αναπτυχθεί σε πειραματικό στάδιο από την εταιρία νευροτεχνολογίας Neuralink [30]. Το Link, η συσκευή διεπαφής εγκεφάλου-μηχανής της Neuralink, χρησιμοποιεί μικρά ηλεκτρόδια που εμφυτεύονται στον εγκέφαλο για να καταγράφει την ηλεκτρική δραστηριότητα των νευρώνων. Οι πληροφορίες αυτές αποστέλλονται στη συνέχεια σε έναν υπολογιστή για ανάλυση, ο οποίος τις χρησιμοποιεί για τον έλεγχο εξωτερικών συσκευών, όπως ένας ρομποτικός βραχίονας ή ένας κέρσορας υπολογιστή. Τα ηλεκτρόδια είναι κατασκευασμένα από ένα εύκαμπτο, βιοσυμβατό υλικό που μπορεί να ανιχνεύει τα ηλεκτρικά σήματα, που ονομάζονται επίσης "αιχμές" ή "δυναμικά δράσης", τα οποία παράγονται από τους νευρώνες όταν επικοινωνούν μεταξύ τους. Το τσιπ επεξεργάζεται τα σήματα από τα ηλεκτρόδια και τα στέλνει ασύρματα σε έναν μικρό υπολογιστή που φοριέται πίσω από το αυτί, ο οποίος στη συνέχεια θα συνδέεται με το διαδίκτυο και άλλες συσκευές.

Bibliography

- [1] Ernst Niedermeyer and Fernando Lopes da Silva. *Electroencephalography: Basic Principles, Clinical Applications, and Related Fields*. Lippincott Williams & Wilkins, Philadelphia, PA, 2005.
- [2] Zheng Cao. A review of artificial intelligence for eeg-based brain-computer interfaces and applications. *Brain Science Advances*, 6(3), 2020.
- [3] Xi Chen, Song Qiu, Xiaoyu Wang, Bo Yuan, Teng Zhang, and Nan Chen. A deep learning framework for eeg classification in working memory tasks. *Journal of Neural Engineering*, 17(3), 2020.
- [4] Παυλόπουλος Σ. και Πρέντζα Α. Κουτσούρης Δ. *Εισαγωγή στη Βιοϊατρική Τεχνολογία και Ανάλυση Ιατρικών Σημάτων*. Εκδόσεις Τζιόλα, 2003.
- [5] Ramesh Srinivasan, Don M. Tucker, and Michael Murias. Estimating the spatial nyquist of the human eeg. *Behavior Research Methods, Instruments, & Computers*, 1998.
- [6] Bruce E. Swartz and Elissa S. Goldensohn. Timeline of the history of eeg and associated fields. *Electroencephalography and Clinical Neurophysiology*, 1998.
- [7] H.H. Jasper. The 10 – 20 electrode system of the international federation. *Electroencephalography and Clinical Neurophysiology*, 10, 1958.
- [8] Hans N. Nagel. Biopotential amplifiers. In Joseph D. Bronzino, editor, *The Biomedical Engineering Handbook*. CRC Press, Florida, 1995.
- [9] Δημήτριος Γ. Γαλάνης. Ανίχνευση ρυθμών εγκεφαλικής δραστηριότητας σε ηλεκτροεγκεφαλογραφήματα. Master's thesis, University of Patras, Patra, Greece, 2008.
- [10] Stuart Russell and Peter Norvig. *Artificial Intelligence: A Modern Approach*. PEARSON, 4th us ed. edition, 2022.

- [11] Simon Haykin. *Neural Networks and Learning Machines*. PEARSON, third edition edition, 2014.
- [12] Brian G. Farley and William A. Clark. Simulation of self-organizing systems by digital computer. *Trans. IRE Prof. Group Inf. Theory*, 2017.
- [13] Frank Rosenblatt. The perceptron: A perceiving and recognizing automaton, report 85-60-1. Technical report, Cornell Aeronautical Laboratory, Buffalo, New York, 1957.
- [14] Yang Wang, Yun Li, Yong Sang Song, and Xingsheng Rong. The influence of the activation function in a convolution neural network model of facial expression recognition. *Applied Sciences*, 10(5), 2020.
- [15] Christopher Bishop. *Pattern Recognition and Machine Learning*. Springer, 2006.
- [16] Ν. Φάκας Γ. Ματσόπουλος. Συνδέσεις εγκεφαλικών δικτύων σε καταστάσεις κόπωσης λόγω στέρησης ύπνου σε νοητικές εργασίες λειτουργικής μνήμης και παρατεταμένης προσοχής., 2017.
- [17] Conway, A. R. A., Kane, M. J., and M. F. Bunting. Working memory span tasks: A methodological review and user's guide. *Psychonomic Bulletin & Review*, 12(5), 2005.
- [18] X. Jiang, G.-B. Bian, and Z. Tian. Removal of artifacts from eeg signals: A review. *Sensors (Basel)*, 19(5), Feb 2019.
- [19] A. B. Usakli. Improvement of eeg signal acquisition: An electrical aspect for state of the art of front end. *Comput Intell Neurosci*, 2010, 2010.
- [20] J. W. Leis. *Digital Signal Processing Using MATLAB for Students and Researchers*. John Wiley & Sons, 2011.
- [21] Y. Li, Y. Wang, B. Zhang, Y. Wang, and X. Zhou. Electrophysiological responses to expectancy violations in semantic and gambling tasks: A comparison of different eeg reference approaches. *Front. Neurosci.*, 12, 2018.
- [22] M. D. Lutovac, D. V. Tošić, and B. L. Evans. *Filter Design for Signal Processing Using MATLAB and Mathematica*. Miroslav Lutovac, 2001.

-
- [23] M. Bianchi, M. Boyle, and D. Hollingsworth. A comparison of methods for trend estimation. *Applied Economics Letters*, 6(2), Feb 1999.
- [24] T. P. Jung, S. Makeig, M. Westerfield, J. Townsend, E. Courchesne, and T. J. Sejnowski. Removal of eye activity artifacts from visual event-related potentials in normal and clinical subjects. *Clin Neurophysiol*, 111(10), Oct 2000.
- [25] P. M. Alday. How much baseline correction do we need in erp research? extended glm model can replace baseline correction while lifting its limits. *Psychophysiology*, 56(12), Dec 2019.
- [26] T. P. Jung and et al. Removing electroencephalographic artifacts by blind source separation. *Psychophysiology*, 37(2), Mar 2000.
- [27] A. Delorme and S. Makeig. Eeglab: an open source toolbox for analysis of single-trial eeg dynamics including independent component analysis. *Journal of Neuroscience Methods*, 134(1), Mar 2004.
- [28] Mne — mne 1.4.2 documentation. Mne.tools, June 29 2023.
- [29] An introduction to dynamic time warping. Built In, 2022.
- [30] Introduction to neuralink. FindLight Blog, March 15 2023.

APPENDICES

Appendix A

Κωδικας

A.1 Βασικός κώδικας

```
#global hyperparameters dictionary
class ParamDict(dict):
    __getattr__ = dict.__getitem__
    __setattr__ = dict.__setitem__

param_dict = {
    'n_experiments': 10, # number of repetitions
    'n_elects': 40, #number of electrodes used
    'n_epochs': 8, # number of epochs trained
    'n_batch_size': 32, # size of batches to be trained
    'n_filters': [256],# size of filter for the convolution
    'n_kernel': 5, # kernel size for convolution
    'n_pool_size': 4, # maxpooling layer size
    'n_dropout_rate': 0.2,# % of data to drop in dropout layer
    'n_activation': 'relu', # type of activation function
    'n_neurons': 2000 # number of neurons in dense layer
}

param_grid = ParamDict(param_dict)
class_names = ['Rested','Fatigued']

#change dataset dimentions
def fix_dimentions(dataset):
    temp = np.dstack(dataset)
```

```

fixed = np.transpose(temp, [2,0,1])
return fixed
# fit and evaluate a model
def evaluate_model(trainX, trainy, testX, testy):
    verbose, epochs, batch_size = 1,
                                param_grid.n_epochs,
                                param_grid.n_batch_size
    n_timesteps, n_features, n_outputs = trainX.shape[1],
                                        trainX.shape[2],
                                        trainy.shape[1]

    model = Sequential()
    model.add(Conv1D(filters = param_grid.n_filters[0],
                    kernel_size = param_grid.n_kernel,
                    activation = param_grid.n_activation,
                    input_shape=(n_timesteps,n_features)))
    model.add(Dropout(param_grid.n_dropout_rate))
    model.add(MaxPooling1D(pool_size = param_grid.n_pool_size))
    model.add(Flatten())
    model.add(Dense(param_grid.n_neurons,
                    activation = param_grid.n_activation))
    model.add(Dense(n_outputs, activation='sigmoid'))
    plot_model(model, show_shapes=True, to_file='multichannel.png')
    model.compile(loss='binary_crossentropy',
                  optimizer='adam',
                  metrics=['accuracy'])

    #make callbacks
    # fit network
    model.fit(trainX, trainy,
              epochs=epochs,
              batch_size=batch_size,
              shuffle = True, verbose=verbose)

    # evaluate model
    _, accuracy = model.evaluate(testX,
                                testy,
                                batch_size=batch_size,
                                verbose=verbose)

    #ynew = model.predict_classes(testy)
    y_pred=model.predict(testX)
    y_pred=np.argmax(y_pred, axis=1)

```



```

y_test=np.argmax(testy, axis=1)
cm = confusion_matrix(y_test, y_pred)
# print classification report
print('classification report \n',
      classification_report(y_test,
                            y_pred,
                            zero_division=0))
show_confusion_matrix(cm, class_names)
#print('Confusion Matrix \n',cm)
return accuracy

# summarize scores
def summarize_results(scores):
print(scores)
# summarize mean and standard deviation
for i in range(len(scores)):
m, s = mean(scores[i]), std(scores[i])
print('Hyperparameters', param_grid)
print('Accuracy: \x1b[31m%.3f%%\x1b[0m (+/-%.3f)' % (m, s))
# boxplot of scores
pyplot.boxplot(scores)
pyplot.savefig('exp_cnn_kernel.png')
return m,s

def store_results(mean,std, start):
time_spend = time.time() - start
res_file = 'Desktop\\temp\\results.txt'
param_grid['n_MEAN'] = round(mean,2)
param_grid['n_std'] = round(std,2)
param_grid['n_time(mins)'] = round(time_spend/60,2)
print(param_grid)
with open(res_file, 'a') as results_file:
results_file.write("{}\n".format(json.dumps(param_grid)))
#results_file.write("/n")

Ready_dataset, Best_elecs = keep_best_elecs(param_grid.n_elecs,
                                             total_answers)

# run an experiment
def run_experiment(repeats=1):

```

```

start_time = time.time()
# test each parameter
all_scores = list()
# repeat experiment
scores = list()
for r in range(repeats):
# load data
seed = np.random.randint(1, 5000)
print("This split's seed is: ", seed)
train_df, test_df, train_l, test_l = train_test_split(Ready_dataset,
                                                    labels,
                                                    test_size=0.25,
                                                    random_state=seed,
                                                    shuffle = True,
                                                    stratify = labels)

print("data dimentions")
trainX = fix_dimentions(train_df)
print("trainX: ", trainX.shape)
testX = fix_dimentions(test_df)
print("testX: ", testX.shape)
trainy = tf.one_hot(np.array(train_l), depth=2)
print("trainy: ", trainy.shape)
testy = tf.one_hot(np.array(test_l), depth=2)
print("testy: ", testy.shape)

score = evaluate_model(trainX, trainy, testX, testy)
score = score * 100.0

print('Experiment # %d score : \x1b[31m%.3f%%\x1b[0m' % (r+1, score))
scores.append(score)
all_scores.append(scores)
# summarize results
r_mean, r_std = summarize_results(all_scores)
store_results(r_mean, r_std, start_time)
# notify when done
display(IPython.display.Audio(url="https://static.sfdict.com/audio/C07/C0702600.mp3",
                              autoplay=True))

# run the experiment
%time run_experiment(param_grid.n_experiments)

```

A.2 Βοηθητικές συναρτήσεις

```
def load_and_split_answers(path):
    eeglab_raw = mne.io.read_raw_eeglab(path, verbose='error')
    #print(eeglab_raw.info)

    custom_mapping = {'1': 1, '11': 11, '12': 12, '13': 13, '2': 2, '3': 3, '4': 4, '5': 5}
    (events_from_annot,
    event_dict) = mne.events_from_annotations(eeglab_raw, event_id=custom_mapping)
    raw_df = eeglab_raw.to_data_frame()
    answers_df = []
    wrong_answers_df = []
    pd.options.mode.chained_assignment = None
    label_no = len(events_from_annot) #rows
    event_labels = events_from_annot[:,2] #3rd column
    event_index = events_from_annot[:,0] #index to raw data
    right_answers_start = []
    wrong_answers_start = []
    for i in range(0,label_no-2):
        current = int(event_labels[i])
        next = int(event_labels[i+1])
        current_ind = int(event_index[i])
        next_ind = int(event_index[i+1])
        if (current == 1):
            if (next != 11):
                wrong_answers_start.append(current_ind)
            else:
                right_answers_start.append(current_ind)

        if (current == 2):
            if (next != 12):
                wrong_answers_start.append(current_ind)
            else:
                right_answers_start.append(current_ind)

        if (current == 3):
            if (next != 13):
```

```

        wrong_answers_start.append(current_ind)
    else:
        right_answers_start.append(current_ind)

    if (current == 4):
        if (next != 1 and next != 2 and next != 3):
            wrong_answers_start.append(current_ind)
        else:
            right_answers_start.append(current_ind)

def add_answer_column(start,type, raw_df = raw_df):
    step = 1024 # no of frames checked for each answer
    df = []
    for i in range(0,len(start)):
        df.append(raw_df.iloc[start[i]:start[i] + step])
        #1:right answer 0:wrong answer
        if type == 1:
            df[i].loc[:,['Answer type']] = type
        else:
            df[i].loc[:,['Answer type']] = type
    return df

answers_df = add_answer_column(right_answers_start,1)
wrong_answers_df = add_answer_column(wrong_answers_start,0)
#list no_of_right x 1024 x 65
print("No of right answers:", len(answers_df))
#list no_of_wrong x 1024 x 65
print("No of wrong answers:", len(wrong_answers_df))
for i in wrong_answers_df:
    answers_df.append(i)
return answers_df

local_folder_path = 'Desktop\\temp\\thesis_data'
folder_path = '/content/drive/MyDrive/Thesis/matlab_nback/nback/all'
filenames = []

for subdir, dirs, files in os.walk(local_folder_path):
    for file in files:
        if os.path.join(subdir, file)[-4:] == '.set':
            filenames.append(os.path.join(subdir, file))

```

```

print (filenames)

experiments = len(filenames) #40 eegs taken
answers = [[] for i in range(0,experiments)]
for file in filenames:
    index = filenames.index(file)
    answers[index]= load_and_split_answers(file)
    print('total answers length for file: ',index , 'is',len(answers[index]))
#answers dimention [40,72,66,1024] 40 experiments with 72 answers of
#66x1024 dimention dataframes each
#(1024 frames x 64 elec + state + answer_type)

def isRested(name):
    if name[-28] == 'R': #check the name string
        return True
    else:
        return False

for i in range(0,len(answers)):
    if isRested(filenames[i]):
        for j in range(0,len(answers[i])):
            answers[i][j].loc[:,['State']] = 0 #0:rested 1:fatigued
    else:
        for j in range(0,len(answers[i])):
            answers[i][j].loc[:,['State']] = 1 #0:rested 1:fatigued

total_answers = [] #list of 2866 answers (dataframes[1024x66])
for exp in answers:
    for ans in exp:
        total_answers.append(ans)

def show_confusion_matrix(confusion_matrix, class_names):

    cm = confusion_matrix.copy()

    cell_counts = cm.flatten()

    cm_row_norm = cm / cm.sum(axis=1)[:, np.newaxis]

```

```

row_percentages = [{"0:.2f}".format(value) for value in cm_row_norm.flatten()]

cell_labels = [f"{cnt}\n{per}" for cnt,
                per in zip(cell_counts,
                            row_percentages)]
cell_labels = np.asarray(cell_labels).reshape(cm.shape[0], cm.shape[1])

df_cm = pd.DataFrame(cm_row_norm,
                     index=class_names,
                     columns=class_names)

hmap = sns.heatmap(df_cm, annot=cell_labels, fmt="", cmap="Blues")
hmap.yaxis.set_ticklabels(hmap.yaxis.get_ticklabels(),
                          rotation=0,
                          ha='right')
hmap.xaxis.set_ticklabels(hmap.xaxis.get_ticklabels(),
                          rotation=30,
                          ha='right')

plt.ylabel('True State')
plt.xlabel('Predicted State');

def make_labels(dataset):
    labels = []
    types = []
    for i in range(0, len(dataset)):
        labels.append(int(dataset[i]['State'].head(1)))
        types.append(int(dataset[i]['Answer type'].head(1)))
        #delete state column from dataset after extracting as label
        del dataset[i]['State']
        #delete answer type column after extracting it from the dataset
        del dataset[i]['Answer type']
        #delete time column from the dataset
        del dataset[i]['time']
    return labels

def keep_best_elects(num, dataset): # num of electrodes to keep
    samples = len(dataset) #40
    elec_mean = [[] for i in range(samples)]

```

```
ready_timeframes = [[] for i in range(samples)]
for i in range(samples):
    elec_mean[i] = dataset[i].mean()
con = pd.concat(elec_mean,axis=1).T
best_elecs = con.std().sort_values(ascending=False).head(num).index.to_list()
#change flag to true for min std electrodes
print("found best electrodes to keep:", best_elecs)
for i in range(samples):
    ready_timeframes[i] = dataset[i][best_elecs]
return ready_timeframes, best_elecs
```

A.3 Imports

```
import mne
import pandas as pd
import numpy as np
import os
from sklearn.metrics import confusion_matrix, accuracy_score
from sklearn.preprocessing import StandardScaler
from keras.models import Sequential
from keras.layers import Dense
from keras.layers import Flatten
from keras.layers import Dropout
from keras.layers.convolutional import Conv1D
from keras.layers.convolutional import MaxPooling1D
import tensorflow as tf
from tensorflow.keras.utils import to_categorical
import matplotlib.pyplot as plt
import numpy as np
from sklearn.model_selection import cross_validate, train_test_split
from sklearn.preprocessing import PolynomialFeatures, StandardScaler
from sklearn.pipeline import make_pipeline
from sklearn.linear_model import LinearRegression
from sklearn.metrics import mean_squared_error
from numpy import mean
from numpy import std
from numpy import dstack
```

```
from matplotlib import pyplot
import json
from sklearn.metrics import classification_report, confusion_matrix
from tensorflow.keras import layers
from tensorflow.keras import regularizers
from keras.utils.vis_utils import plot_model
import IPython
```