



Εθνικό Μετσόβιο Πολυτεχνείο
Σχολή Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών
Τομέας Τεχνολογίας Πληροφορικής και Υπολογιστών

**Ταξινόμηση σημάτων Ηλεκτροεγκεφαλογραφήματος
νοητικών κινήσεων με τη χρήση Τεχνητού Νευρωνικού
Δικτύου Αιχμών και Νευρομορφικού Υλικού**

Διπλωματική Εργασία

του

Ηλία Π. Παναγιωταρά

Επιβλέπων: Ανδρέας-Γεώργιος Σταφυλοπάτης
Καθηγητής Ε.Μ.Π.

Εργαστήριο Συστημάτων Τεχνητής Νοημοσύνης και Μάθησης
Αθήνα, Σεπτέμβριος 2020



Εθνικό Μετσόβιο Πολυτεχνείο
Σχολή Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών
Τομέας Τεχνολογίας Πληροφορικής και Υπολογιστών
Εργαστήριο Συστημάτων Τεχνητής Νοημοσύνης και Μάθησης

Ταξινόμηση σημάτων Ηλεκτροεγκεφαλογραφήματος νοητικών κινήσεων με τη χρήση Τεχνητού Νευρωνικού Δικτύου Αιχμών και Νευρομορφικού Υλικού

Διπλωματική Εργασία

του

Ηλία Π. Παναγιωταρά

Επιβλέπων: Ανδρέας-Γεώργιος Σταφυλοπάτης
Καθηγητής Ε.Μ.Π.

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 10^η Σεπτεμβρίου, 2020.

.....
Ανδρέας-Γεώργιος Σταφυλοπάτης
Καθηγητής Ε.Μ.Π.

.....
Γιώργος Στάμου
Αν. Καθηγητής Ε.Μ.Π.

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

Αθήνα, Σεπτέμβριος 2020

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

Copyright © – All rights reserved Ηλίας Π. Παναγιωταράς, 2020.

Με επιφύλαξη παντός δικαιώματος.

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

Μη επεμβατικές Διεπαφές Εγκεφάλου-Υπολογιστή (ΔΕΥ) που κάνουν χρήση σημάτων Ηλεκτροεγκεφαλογραφήματος (ΗΕΓ) νοητικών κινήσεων, είναι υπεύθυνες για την μετάφραση της πρόθεσης του χρήστη για την κίνηση ενός άκρου του σε σήματα ελέγχου, ταξινομώντας τα μοτίβα ΗΕΓ που παράγονται από διαφορετικές νοητικές εργασίες, όπως η νοητική κίνηση των χεριών. Οι ΔΕΥ αυτής της μορφής έχουν μελετηθεί εκτενώς και χρησιμοποιούνται ήδη ως εναλλακτικός τρόπος επικοινωνίας και ελέγχου του περιβάλλοντος των ανθρώπων με αναπηρία, όπως ασθενείς που υποφέρουν από Πλάγια Μυατροφική Σκλήρυνση, εγκεφαλικό επεισόδιο και κάκωση του νωτιαίου μυελού. Η συμβίωση του αναπτυσσόμενου κλάδου των ΔΕΥ με τις πρόσφατες εξελίξεις στην Νευρομορφική Υπολογιστική, η οποίες επιτρέπουν την χαμηλής ισχύος υλοποίηση Νευρωνικών Δικτύων Αιχμών μεγάλης κλίμακας για την επεξεργασία δεδομένων σε πραγματικό χρόνο, μπορεί να οφελήσει σημαντικά μία πληθώρα από εφαρμογές διαφορετικών κλάδων.

Στην παρούσα εργασία, υλοποιούμε και αναπτύσσουμε περαιτέρω ένα μοντέλο Νευρωνικού Δικτύου Αιχμών (ΝΔΑ), το οποίο είναι εμπνευσμένο από την αρχιτεκτονική του οσφρητικού συστήματος των εντόμων, για την αποκωδικοποίηση και πρόβλεψη νοητικών κινήσεων από σήματα ΗΕΓ. Το δίκτυο εκτελέστηκε στην πλατφόρμα νευρομορφικού υλικού SpiNNaker, η οποία αποτελείται από 4 ολοκληρωμένα κυκλώματα με 64 πυρήνες. Για την βελτίωση της απόδοσης του δικτύου, υλοποιήθηκε ένας αλγόριθμος μάθησης ανταμοιβής Spike-Time Dependent Plasticity (STDP), ενώ ελέγχθηκαν και άλλες τεχνικές, όπως η Ομοιόσταση και η μαζική μάθηση (batch learning) για την εκπαίδευση του δικτύου. Έχοντας ως στόχο την εύρεση συστατικών από τα σήματα ΗΕΓ, τα οποία να είναι σταθερά κατα μήκος των νοητικών κινήσεων της ίδιας κλάσης, αναλύθηκαν διάφορες τεχνικές εξαγωγής χαρακτηριστικών, όπως ο υπολογισμός της ισχύος υποζώνης συχνοτήτων, της λογαριθμικής ισχύος ζώνης και χαρακτηριστικών που παρουσιάζονται κατα τη διάρκεια μίας νοητικής κίνησης, από τα διαθέσιμα σήματα. Ελέγχθηκε, ακόμα, ο Διακριτός Μετασχηματισμός Κυματιδίων (ΔΜΚ), για την αποσύνθεση των δεδομένων ΗΕΓ, διατηρώντας την πληροφορία από τα πεδία του χρόνου και της συχνότητας.

Από όλες τις προσεγγίσεις για την εξαγωγή σταθερών χαρακτηριστικών, ο ΔΜΚ απεδείχθη να έχει τα καλύτερα αποτελέσματα. Συνολικά, το Νευρωνικό Δίκτυο Αιχμών, εκπαιδευμένο με τη χρήση του αλγορίθμου μάθησης STDP, πετυχαίνει μέση ορθότητα ταξινόμησης 70.3%, ποσοστό 5.23% μικρότερο κατά μέσο όρο σε σύγκριση με τα αντίστοιχα ποσοστά των παραδοσιακών στατιστικών αλγορίθμων μάθησης. Τα αποτελέσματα, μεταξύ άλλων, μας υποδεικνύουν πως τα ΝΔΑ αποτελούν μία βάσιμη εναλλακτική των κλασικών αλγορίθμων μηχανικής μάθησης για τη χρήση σε εφαρμογές ΔΕΥ, εάν ληφθεί υπόψη η μείωση της κατανάλωσης ισχύος και των χρόνων εκπαίδευσης που παρουσιάζουν όπως αποδεικνύεται στη βιβλιογραφία.

Λέξεις Κλειδιά

Διεπαφές Εγκεφάλου-Υπολογιστή, Τεχνητά Νευρωνικά Δίκτυα Αιχμών, Νευρομορφική Υπολογιστική, Ηλεκτροεγκεφαλογράφημα

Abstract

Non-invasive, Electroencephalography (EEG) based brain-computer interfaces (BCIs) on motor imagery movements translate the subject's motor intention into control signals through classifying the EEG patterns caused by different imagination tasks, e.g. hand movements. This type of BCI has been widely studied and is already used as an alternate mode of communication and environmental control for the disabled, such as patients suffering from amyotrophic lateral sclerosis, brainstem stroke and spinal cord injury. Together with recent advancements in neuromorphic computing, which allow real-time, low power implementations of large scale spiking models for data processing, BCI applications could profit from this symbiosis.

Inspired from the architecture of the insect's olfactory system, we further advance and implement a spiking neural network model to decode and predict imaginary movements from EEG signals. The network runs on SpiNNaker, a neuromorphic hardware platform containing 4 chips with 64 cores. To improve the network's performance a reward based Spike-Time Dependent Plasticity (STDP) learning algorithm is implemented and different techniques, such as Homeostasis and batch-learning for training the network are tested. Aiming to find EEG signal components that are stable across imagery movements of the same type we further implemented and analyzed multiple feature extraction techniques such as calculating sub-band power, logarithmic band power and motor imagery specific characteristics from the signal. Additionally we tested the Discrete Wavelet Transform (DWT) to decompose the EEG data while preserving information from the frequency as well as the time domain.

Of all approaches to extract stable characteristics the DWT proved to yield the best results. Overall the spiking neural network reaches with the STDP learning algorithm a mean accuracy of 70.3% only falls short by an average of 5.23% in classification rate to state of the art machine learning algorithms. This shows SNNs present a valid alternative to classical machine learning algorithms deployed in BCIs, if the reduced training time and the smaller energy footprint are taken into consideration, as presented in the literature.

Keywords

Brain-Computer Interfaces, Spiking Neural Networks, Neuromorphic Computing, Electroencephalogram

Ευχαριστίες

Η εκπόνηση της Διπλωματικής μου εργασίας σηματοδοτεί το τέλος των προπτυχιακών σπουδών μου στη Σχολή Ηλεκτρολόγων Μηχανικών και Μηχανικών Υπολογιστών του Εθνικού Μετσόβιου Πολυτεχνείου. Πραγματοποιήθηκε στα πλαίσια του Εργαστηρίου Ευφυών και Υπολογιστικών Συστημάτων του τομέα Τεχνολογίας Πληροφορικής και Υπολογιστών, με επιβλέποντα καθηγητή τον κ. Ανδρέα Σταφυλοπάτη, τον οποίο και θα ήθελα να ευχαριστήσω πρωτίστως για την ευκαιρία που μου έδωσε να ασχοληθώ με το συγκεκριμένο επιστημονικό πεδίο, αλλά και για τα άτομα με τα οποία ο ίδιος με έφερε σε επικοινωνία και υπήρξαν αρωγοί στην προσπάθειά μου.

Ιδιαίτερως θα ήθελα να ευχαριστήσω τον κύριο Δρ. Γεώργιο Σιόλα ο οποίος στάθηκε δίπλα μου από την αρχή, δίνοντας μου τις κατάλληλες συμβουλές και κατευθύνσεις, προκειμένου να έχουμε το επιθυμητό αποτέλεσμα, με την βοήθεια του οποίου η συγκεκριμένη διπλωματική έγινε πραγματικότητα. Θα ήθελα επίσης να ευχαριστήσω την καθηγήτρια Κωνσταντίνα Νικήτα και τον καθηγητή Γεώργιο Στάμου οι οποίοι με τις γόνιμες συμβουλές και κατευθύνσεις τους με οδήγησαν στο να επιλέξω το συγκεκριμένο θέμα.

Τέλος, ευχαριστώ βαθύτατα τους γονείς μου Πέτρο και Ελένη καθώς και την αδερφή μου Ευαγγελία για την αγάπη, την υπομονή και την στήριξη που μου έχουν προσφέρει όλα αυτά τα χρόνια.

Ηλίας Π. Παναγιωταράς

Στους γονείς μου, Πέτρο και Ελένη
Στην αδελφή μου, Εύα

Περιεχόμενα

Περίληψη	5
Abstract	7
Ευχαριστίες	9
Περιεχόμενα	12
Σχήματα	14
Πίνακες	15
1 Εισαγωγή	17
1.1 Τεχνητή Νοημοσύνη και Νευροεπιστήμη	17
1.2 Διεπαφές Εγκεφάλου-Υπολογιστή	18
1.3 Νευρομορφική Υπολογιστική	18
1.4 Κίνητρο	19
1.5 Σκοπός	19
1.6 Ερευνητικά Ερωτήματα	20
1.7 Διάρθρωση Εργασίας	21
2 Θεωρητικό Υπόβαθρο	23
2.1 Βασικές Αρχές Διεπαφών Εγκεφάλου-Υπολογιστή	23
2.1.1 Δομή του εγκεφάλου και απόκτηση εγκεφαλικών σημάτων	23
2.1.2 Συνήθεις δείκτες ΗΕΓ σε Διεπαφές Εγκεφάλου - Υπολογιστή	25
2.2 Ανίχνευση νοητικών κινήσεων μέσω ΗΕΓ	29
2.2.1 Χαρακτηριστικά σημάτων ΗΕΓ που αντιστοιχούν σε νοητικές κινήσεις	29
2.2.2 Καταγραφή δεδομένων νοητικών κινήσεων μέσω ΗΕΓ	30
2.3 Νευρωνικά Δίκτυα Αιχμών	30
2.3.1 Νευροφυσιολογία του ανθρώπινου εγκεφάλου	31
2.3.2 Νευρωνική Κωδικοποίηση	33
2.3.3 Μοντελοποίηση νευρώνων	37
2.3.4 Συναπτική πλαστικότητα και μάθηση	42
2.3.5 Προσομοίωση Νευρωνικών Δικτύων Αιχμών	44
3 Τεχνικό Υπόβαθρο	49
3.1 Τεχνολογίες Προεπεξεργασίας Δεδομένων	49
3.1.1 General Data Format - GDF	49
3.1.2 Εργαλειοθήκη BioSig	50
3.1.3 MNE-Python	50

3.1.4	Functional Image File Format - FIFF	50
3.2	Εργαλεία Εξαγωγής Χαρακτηριστικών	51
3.2.1	Βιβλιοθήκη NumPy	51
3.2.2	Βιβλιοθήκη SciPy	51
3.3	Προσομοίωση Νευρωνικών Δικτύων Αιχμών σε Νευρομορφικό Υλικό	52
3.3.1	Human Brain Project	52
3.3.2	Η γλώσσα περιγραφής Νευρωνικών Δικτύων PyNN	53
3.3.3	Το πακέτο sPyNNaker	57
4	Συγγενείς Εργασίες	59
4.1	Διεπαφές Εγκεφάλου-Υπολογιστή με χρήση δεδομένων ΗΕΓ	59
4.2	Μέθοδοι Αποκωδικοποίησης Νοητικών Κινήσεων από δεδομένα ΗΕΓ	60
4.3	Νευρωνικό Δίκτυο Αιχμών για την ταξινόμηση δεδομένων ΗΕΓ	63
5	Αρχιτεκτονική	67
5.1	Εξαγωγή και Ταξινόμηση Χαρακτηριστικών ΗΕΓ	67
5.2	Πειραματικά Δεδομένα	68
6	Πειραματική Διαδικασία και Αποτελέσματα	71
6.1	Προεπεξεργασία δεδομένων	71
6.2	Εξαγωγή Χαρακτηριστικών	72
6.2.1	Γεγονότα Συγχρονισμού και Αποσυγχρονισμού	72
6.2.2	Διακριτός Μετασχηματισμός Κυματιδίων	74
6.2.3	Κωδικοποίηση κατά μήκος των δοκιμών	75
6.3	Υλοποίηση Νευρωνικού Δικτύου Αιχμών	76
6.3.1	Κωδικοποίηση Χαρακτηριστικών	76
6.3.2	Υλοποίηση Δικτύου	77
6.4	Αποτελέσματα	80
6.4.1	Στατιστικοί Ταξινομητές	80
6.4.2	Νευρωνικό Δίκτυο Αιχμών	81
6.4.3	Σύγκριση Νευρωνικού Δικτύου Αιχμών με Στατιστικούς Ταξινομητές	84
7	Επίλογος	87
7.1	Συμπεράσματα και Μελλοντικές Επεκτάσεις	87
7.2	Συζήτηση	89
7.2.1	Συμβίωση Ανθρώπου-Μηχανής	89
7.2.2	Νευρομορφική Τεχνητή Νοημοσύνη	90
	Ακρωνύμια	93
	Βιβλιογραφία	95

Σχήματα

1.1	Διάρθρωση της εργασίας	21
2.1	Πλευρική όψη των λοβών του ανθρώπινου εγκεφάλου	24
2.2	Διεθνές σύστημα τοποθέτησης ηλεκτροδίων 10/20	25
2.3	Φιλτραρισμένες καταγραφές ΗΕΓ από το ηλεκτρόδιο Oz	26
2.4	Καταγραφές της εγκεφαλικής δραστηριότητας	27
2.5	Το πλέγμα γραμμάτων του Ορθογράφου P300	28
2.6	2Δ εφαρμογή ΔΕΥ η οποία υποδεικνύει την νοητική κατάσταση χρήστη	28
2.7	Οι δομές του σωματοαισθητηριακού και του κινητικού φλοιού, μαζί με τις αντίστοιχες λειτουργίες τους	30
2.8	Δοκιμή μιας τυπικής συνεδριας καταγραφής νοητικών κινήσεων	31
2.9	Λειτουργικά μέρη ενός βιολογικού νευρώνα	32
2.10	Παράδειγμα Κωδικοποίησης Ρυθμού νευρωνικών σημάτων	35
2.11	Κωδικοποίηση Πληθυσμού με Γκαουσιανά Δεκτικά Πεδία	35
2.12	Γραφικές παραστάσεις διεγερτικού και ανασταλτικού μετασυναπτικού δυναμικού	37
2.13	Οπτική αναπαράσταση άθροισης μετασυναπτικών δυναμικών	38
2.14	Σύγκριση μεταξύ του μηχανισμού επεξεργασίας ενός τεχνητού νευρώνα και ενός νευρώνα αιχμών	39
2.15	Μοντελοποίηση κυτταρικής μεμβράνης	40
2.16	Παρουσίαση του μηχανισμού μάθησης STDP	43
2.17	Η αρχιτεκτονική του νευρομορφικού υπολογιστικού συστήματος SpiNNaker	46
2.18	Εσωτερική όψη πλακέτας 48 κόμβων του νευρομορφικού συστήματος SpiNNaker	46
2.19	Το νευρομορφικό σύστημα SpiNNaker του Human Brain Project	47
2.20	Εξωτερική όψη πλακέτας 48 κόμβων του νευρομορφικού συστήματος SpiNNaker	47
4.1	Αποσύνθεση του σήματος $f(t)$ σε συνιστώσες με χρήση του DWT 4 επιπέδων	62
4.2	Αποσύνθεση σήματος ΗΕΓ σε συντελεστές με χρήση του DWT 6 επιπέδων	63
4.3	Η αρχιτεκτονική 3 επιπέδων του Νευρωνικού Δικτύου Αιχμών των Schmuker et al	65
5.1	Καταγραφή σημάτων ΗΕΓ από το Πανεπιστήμιο του Γκκρατς στα πλαίσια του BCI Competition 2003	69
5.2	Καταγραφή σημάτων ΗΕΓ από το Πανεπιστήμιο του Γκκρατς στα πλαίσια του BCI Competition 2008	69
6.1	Χρονικά παράθυρα των ERS/ERD στις ζώνες άλφα και βήτα	73
6.2	Ανάλυση κυματιδίων των σημάτων $C3$ και $C4$ που αντιστοιχούν σε νοητικές κινήσεις του αριστερού χεριού	75
6.3	Το μοντέλο του Νευρωνικού Δικτύου Αιχμών των Schmuker et al.	78

6.4	Υλοποίηση του Νευρωνικού Δικτύου Αιχμών στην πλατφόρμα νευρομορφικού υλικού SpiNNaker	79
-----	---	----

Πίνακες

6.1	Διαφορές μοτίβων (<i>PDs</i>) για τα τρία πρώτα υποκείμενα των δεδομένων του 2008	74
6.2	Συντελεστές Διακριτού Μετασχηματισμού Κυματιδίων επιπέδου 6 σήματος ΗΕΓ με συχνότητα δειγματοληψίας $128Hz$	75
6.3	Αποτελέσματα ταξινόμησης δεδομένων με τη χρήση στατιστικών ταξινομητών	81
6.4	Βέλτιστοι παράμετροι Νευρωνικού Δικτύου Αιχμών	82
6.5	Παράμετροι του μοντέλου νευρώνων Leaky Integrate-and-Fire	82
6.6	Παράμετροι Νευρωνικού Δικτύου Αιχμών για μαζική μάθηση	83
6.7	Σύγκριση μεταξύ διαφορετικών εργασιών ταξινόμησης νοητικών κινήσεων σε δύο κλάσεις	84
6.8	Σύγκριση των αποτελεσμάτων ταξινόμησης των στατιστικών ταξινομητών και του Νευρωνικού Δικτύου Αιχμών	85

Κεφάλαιο 1

Εισαγωγή

“The hardest part of research is always to find a question that’s big enough that it’s worth answering, but little enough that you actually can answer it.”

— Edward Witten

1.1 Τεχνητή Νοημοσύνη και Νευροεπιστήμη

Από τις αρχές του 19ου αιώνα έχει σημειωθεί σημαντική πρόοδος στην Νευροεπιστήμη και την Τεχνητή Νοημοσύνη. Με τη ραγδαία άνοδο των υπολογιστών στο προσκήνιο της επιστήμης, η πρόοδος στην Τεχνητή Νοημοσύνη - TN (Artificial Intelligence - AI) συνδέθηκε άρρηκτα με τη Νευροεπιστήμη και την Ψυχολογία, ενώ πολλοί από τους πρωτοπόρους του τομέα ασχολήθηκαν εκτενώς και με τους δύο κλάδους. Οι συνεργασίες μεταξύ αυτών των επιστημών εν τέλει αποδείχθηκε εξαιρετικά παραγωγική [100, 38, 67, 37]. Παράλληλα, τα τελευταία χρόνια μας έχουν δείξει πως αυτή η αλληλεπίδραση πρόκειται να γίνει ολοένα και πιο στενή και συχνή, δεδομένου πως η πολυπλοκότητα των προβλημάτων που αντιμετωπίζουν τα δύο επιστημονικά πεδία έχει γνωρίσει μαζική εξέλιξη.

Η ανάπτυξη της Τεχνητής Νοημοσύνης ξεκίνησε με την υπόθεση ότι η δημιουργία ανθρωπόμορφης TN γενικού σκοπού (general purpose AI) είναι ένας τρομακτικά δύσκολος στόχος, λόγω του τεράστιου χώρου αναζήτησης των λύσεων. Έτσι, αναδείχθηκε η χρησιμότητα της εξέτασης των αρχών λειτουργίας του ανθρώπινου εγκεφάλου, της υπολογιστικής μηχανής που αποτελεί την μοναδική υπάρχουσα απόδειξη ότι μία τέτοιου τύπου νοημοσύνη είναι δυνατή. Όπως περιγράφουν οι Hassabis et al. [35], το όφελος της δημιουργίας συστημάτων TN που λαμβάνουν εμπνεύσεις από την βιολογική νοημοσύνη είναι διττό. Πρώτον, η Νευροεπιστήμη παρέχει μία πλούσια πηγή έμπνευσης για νέους αλγόριθμους και αρχιτεκτονικές, ανεξάρτητες και συμπληρωματικές με τις υπάρχουσες μαθηματικές μεθόδους, αλλά και ιδέες που έχουν ήδη κυριαρχήσει σε μεγάλο βαθμό έναντι των παραδοσιακών προσεγγίσεων TN, με χαρακτηριστικό παράδειγμα την Βαθιά Μάθηση (Deep Learning). Εν γένει, κάθε νέα μονάδα βιολογικού υπολογισμού που βρίσκεται να είναι κρίσιμη για την υποστήριξη μιας γνωστικής λειτουργίας, θεωρείται εξαιρετικός υποψήφιος για την ενσωμάτωση σε τεχνητά υπολογιστικά συστήματα. Κατα δεύτερον, η Νευροεπιστήμη δύναται να παρέχει επικύρωση σε αλγόριθμους Τεχνητής Νοημοσύνης που εμφανίζονται σήμερα. Εάν ένας γνωστός αλγόριθμος βρεθεί να εφαρμόζεται ήδη σε κάποιο υποσύστημα του ανθρώπινου εγκεφάλου, τότε αυτομάτως ενισχύεται η πεποίθηση ότι ενδεχομένως να αποτελεί αναπόσπαστο συστατικό ενός συστήματος γενικής νοημοσύνης.

1.2 Διεπαφές Εγκεφάλου-Υπολογιστή

Όπως αναφέραμε, επιστήμονες μελετούν επί δεκαετίες τον εγκέφαλο με την ελπίδα ότι θα μπορούν να τον κατανοήσουν και πιθανώς να τον αναπαράγουν. Αυτή η προσπάθεια πυροδότησε την άνοδο του κλάδου της Τεχνητής Νοημοσύνης, όπου η αναπαραγωγή εγκεφαλικών λειτουργιών θεωρείται βασικό θεμέλιο. Η προσφορά της ΤΝ έκτοτε σε κλάδους όπως η Ιατρική και η Νευροεπιστήμη είναι μεγάλη. Συγκεκριμένα, επέτρεψε την καλύτερη ανάλυση και αποκωδικοποίηση ενός μεγάλου εύρους των βιολογικών σημάτων, και ιδιαίτερα αυτών που ξεχωρίζουν για την πολυπλοκότητά τους, όπως το Ηλεκτροεγκεφαλογράφημα - ΗΕΓ (Encephalogram - EEG). Ένας κλάδος που σχετίζεται ιδιαίτερα με τους κλάδους της Τεχνητής Νοημοσύνης και της Νευροεπιστήμης είναι αυτός των Διεπαφών Εγκεφάλου-Υπολογιστή - ΔΕΥ (Brain-Computer Interfaces - BCI). Οι ΔΕΥ, ή πιο γενικά Διεπαφές Εγκεφάλου-Μηχανής (Brain-Machine Interfaces) είναι μία τεχνολογία που καταγράφει ηλεκτροχημικά εγκεφαλικά σήματα, συσχετίζει (ταξινομεί) το σήμα με κάποιο είδος δράσης και στη συνέχεια στέλνει τα κατάλληλα δεδομένα σε ένα υπολογιστικό σύστημα ώστε να αλληλεπιδράσει ο χρήστης με αυτό χωρίς να χρησιμοποιήσει οποιοδήποτε είδος φυσικών κινήσεων. Ουσιαστικά με τη χρήση ΔΕΥ, τα εγκεφαλικά σήματα μετατρέπονται σε μηχανικά κατανοητές εντολές, ώστε να μπορεί να εκτελεστεί ένα συγκεκριμένο είδος δράσης, όπως για παράδειγμα η κίνηση ενός ρομποτικού βραχίονα. Οι επιπτώσεις αυτής της τεχνολογίας μπορούν να φέρουν επανάσταση στις τρέχουσες τεχνολογίες, σε κλάδους όπως η Ιατρική, η ψυχαγωγία και η Επαυξημένη Πραγματικότητα.

Υπάρχουν δύο κύριες μορφές ΔΕΥ, οι επεμβατικές και οι μη-επεμβατικές. Οι επεμβατικές ΔΕΥ περιλαμβάνουν την εμφύτευση ηλεκτροδίων στο κρανίο ή μέσα στην φαία ουσία του εγκεφάλου. Δεδομένου ότι τα ηλεκτρόδια βρίσκονται πιο κοντά στον εγκέφαλο, τα δεδομένα που συλλέγονται είναι πιο ακριβή και περιέχουν λιγότερο θόρυβο. Ωστόσο, η χρήση αυτής της κατηγορίας διεπαφών απαιτεί πολύπλοκη εγκεφαλική χειρουργική επέμβαση και εγείρει σοβαρά ηθικά ζητήματα. Στις μη-επεμβατικές ΔΕΥ, τα ηλεκτρόδια τοποθετούνται γύρω από το κρανίο, συνήθως πάνω σε ένα σκουφάκι που φοράει το υποκείμενο, για την μέτρηση των εγκεφαλικών δραστηριοτήτων από διαφορετικές περιοχές του εγκεφάλου. Σημειώνεται πως σε αυτή την εργασία θα ασχοληθούμε με μη-επεμβατικές διεπαφές.

1.3 Νευρομορφική Υπολογιστική

Οι εξελίξεις στην υπολογιστική ισχύ και τη μηχανική μάθηση έχουν προσδώσει στους υπολογιστές αυξανόμενες επιδόσεις σε γνωστικές δραστηριότητες, όπως η αναγνώριση αντικειμένων [17], οι οποίες κάποτε μπορούσαν μόνο να επιλυθούν από την ανθρώπινη νοημοσύνη μέσω των βιολογικών νευρώνων. Ωστόσο, οι άνθρωποι και πολλά ζώα εξακολουθούν να ξεπερνούν τους υπολογιστές σε πρακτικές εργασίες, όπως η όραση, και όσον αφορά το ενεργειακό κόστος κατα πολλές τάξεις μεγέθους. Αν και φαίνεται να απέχουμε ακόμη πολύ από την πλήρη κατανόηση του ανθρώπινου εγκεφάλου, πιστεύεται ότι το χάσμα απόδοσης μεταξύ του υπολογισμού στο βιολογικό νευρικό σύστημα και σε έναν υπολογιστή έγκειται στη φύση των θεμελιωδών υπολογιστικών μονάδων και στο πως αυτές πραγματοποιούν υπολογισμούς. Ενώ οι τυπικοί υπολογιστές χρησιμοποιούν την Άλγεβρα Μπουλ και ντετερμινιστικές ψηφιακές λειτουργίες, τα νευρικά συστήματα χρησιμοποιούν παράλληλα, κατανεμημένα, καθοδηγούμενα από συμβάντα (event-driven), στοχαστικά αναξιόπιστα [43] δομικά στοιχεία, τους νευρώνες.

Αυτές οι εντυπωσιακές ανισότητες στις γνωστικές ικανότητες καθώς και την κατανάλωση ενέργειας, οδήγησαν την έρευνα σε βιολογικά αποδεκτούς (biologically-plausible) νευρώνες αιχμών (spiking neurons) και αυτοί με τη σειρά τους σε υπολογιστικά συστήματα που λαμβάνουν εμπνεύσεις από τον ανθρώπινο εγκέφαλο για τη λειτουργία τους. Έτσι, γεννήθηκε ο κλάδος της Νευρομορφικής Υπολογιστικής - ΝΥ. Η ΝΥ προτάθηκε από τον Carver Mead στα τέλη της δε-

καετίας του 1980 [70] για την κατασκευή αναλογικών κυκλωμάτων που μιμούνται τα βιολογικά νευρικά κύτταρα και την αρχιτεκτονική του νευρικού συστήματος, κάνοντας χρήση της τεχνολογίας Very-Large-Scale Integration (VLSI). Με απώτερο στόχο την δημιουργία νευρομορφικών μηχανών με Γενική Τεχνητή Νοημοσύνη, ο στόχος της ΝΥ μπορεί να συνοψιστεί ως εξής [23]: η κατανόηση του εγκεφάλου μέσω της μοντελοποίησης και προσομοίωσης των δραστηριοτήτων βιολογικών νευρώνων και η κατασκευή μηχανών που παρομοιάζουν τον εγκέφαλο εφαρμόζοντας βιολογικές αρχές σε υπολογιστικά συστήματα.

1.4 Κίνητρο

Ο τρόπος με τον οποίο οι άνθρωποι αλληλεπιδρούν με την τεχνολογία εξελίσσεται συνεχώς τις τελευταίες δεκαετίες. Διεπαφές, όπως πληκτρολόγια και ποντίκια αντικαθίστανται ολοένα και περισσότερο από σύγχρονες τεχνολογίες, όπως οθόνες αφής, εφαρμογές ελέγχου φωνής και χειρονομιών. Ωστόσο, αυτές θα μπορούσαν να αντικατασταθούν αποκλειστικά από την επόμενη γενιά τεχνολογιών αλληλεπίδρασης ανθρώπου-υπολογιστή, οι οποίες θα χρησιμοποιούν τις ανθρώπινες σκέψεις για τον έλεγχο των συσκευών. Οι Διεπαφές Εγκεφάλου - Υπολογιστή ή πιο γενικά οι Διεπαφές Εγκεφάλου-Μηχανής όντας ένας ταχέως επεκτεινόμενος κλάδος της Νευροεπιστήμης και της Νευρορομποτικής, ήδη εφαρμόζεται με στόχο την ιατρική περίθαλψη και θα μπορούσε περαιτέρω να επιτρέψει μια νέα διάσταση λειτουργικότητας στην παραδοσιακή αλληλεπίδραση ανθρώπου - υπολογιστή. Σήμερα οι ΔΕΥ χρησιμοποιούνται ήδη ως εναλλακτικός τρόπος επικοινωνίας και αλληλεπίδρασης με το περιβάλλον για άτομα με ειδικές ανάγκες, όπως ασθενείς που υποφέρουν από σύνδρομο εγκλεισμού (Locked-In Syndrome), αμυοτροφική πλευρική σκλήρυνση, εγκεφαλικό επεισόδιο ή τραυματισμό του νωτιαίου μυελού. Οι ΔΕΥ αναδύονται επίσης για να αντικαταστήσουν χαμένες αισθητηριακές λειτουργίες υπό τη μορφή προσθετικού κοχλίου ή εμφυτεύματα αμφιβληστροειδούς. Παράλληλα, η έρευνα στα συστήματα BCI έχει χρησιμοποιηθεί με επιτυχία και σε υγιείς ανθρώπους, ως πρόσθετο κανάλι εισόδου δεδομένων σε διάφορες εφαρμογές όπως ο έλεγχος παιχνιδιών, η επαυξημένη πραγματικότητα και ο χειρισμός ρομπότ.

Παράλληλα, η ΝΥ οδήγησε στην ανάπτυξη βιολογικά εμπνευσμένων αρχιτεκτονικών για υπολογιστές, με μακροπρόθεσμο στόχο να προσεγγίσει τις επιδόσεις του ανθρώπινου εγκεφάλου όσον αφορά την ενεργειακή απόδοση και τις γνωστικές ικανότητες. Αν και υπάρχει ήδη ένας αριθμός από διαθέσιμες πλατφόρμες για προσομοιώσεις βιολογικών νευρωνικών δικτύων μεγάλης κλίμακας, το πρόβλημα του προγραμματισμού συστημάτων ώστε να είναι αποδοτικά σε γνωστικές εφαρμογές παραμένει άλυτο. Από την άλλη πλευρά, η Βαθιά Μάθηση κυριαρχεί στην κλάδο των Τεχνητών Νευρωνικών Δικτύων προσφέροντας λύσεις σε γνωστικές δραστηριότητες. Έτσι, ένα βασικό ερευνητικό πρόβλημα είναι η κατανόηση του τρόπου λειτουργίας και η εκπαίδευση βιολογικά εμπνευσμένων νευρωνικών δικτύων, ώστε να γεφυρωθεί το χάσμα μεταξύ αυτών και των νευρωνικών δικτύων που κυριαρχούν σήμερα σε εργασίες Τεχνητής Νοημοσύνης. Επιτρέποντας σε μαζικά παράλληλο νευρομορφικό υλικό (massively-parallel neuromorphic hardware) να παρέχει προηγμένη απόδοση σε προβλήματα Τεχνητής Νοημοσύνης, θα αποτελούσε ένα μεγάλο βήμα προς τη Νευρομορφική Νόηση, ενώ θα συνέβαλε στον απώτερο στόχο της δημιουργίας βιολογικά εμπνευσμένων υπολογιστών με ανθρώπινα επίπεδα ενεργειακής απόδοσης και γνωστικής ικανότητας.

1.5 Σκοπός

Ο εγκέφαλος λειτουργεί ως μία μηχανή επεξεργασίας χωροχρονικών πληροφοριών. Τα χωροχρονικά δεδομένα του εγκεφάλου (Spatio-Temporal Brain Data) είναι τα πιο συχνά συλλεγόμενα δεδομένα για την μέτρηση της εγκεφαλικής απόκρισης σε εξωτερικά ερεθίσματα. Ήδη έχει συλ-

λεχθεί μία τεράστια ποσότητα αντίστοιχων δεδομένων, σε μία προσπάθεια να σημειωθεί πρόοδος στους κλάδους της Ιατρικής, της Νευροεπιστήμης, της Γνωστικής Επιστήμης, της Εκπαίδευσης, της Μηχανικής, αλλά και των Διεπαφών Εγκεφάλου-Υπολογιστή. Ωστόσο, δεν υπάρχει ένα ενοποιητικό υπολογιστικό πλαίσιο για την αντιμετώπιση όλων αυτών των τύπων δεδομένων, προκειμένου να κατανοήσουμε καλύτερα την φύση τους και τις διαδικασίες που τα δημιουργήσαν. Οι τυπικές τεχνικές μηχανικής μάθησης έχουν πετύχει εν μέρη, μιας και δεν είχαν σχεδιαστεί εξαρχής για να αντιμετωπίσουν τόσο πολύπλοκα δεδομένα. Έχει ήδη υποστηριχθεί [51] πως βιολογικά εμπνευσμένοι αλγόριθμοι, όπως τα Νευρωνικά Δίκτυα Αιχμών - ΝΔΑ, είναι κατάλληλα για την δημιουργία ενός ενοποιητικού υπολογιστικού πλαισίου για την μάθηση και την κατανόηση διαφόρων χωροχρονικών εγκεφαλικών δεδομένων, όπως το ΗΕΓ. Ένας από τους λόγους είναι πως τα Τεχνητά Νευρωνικά Δίκτυα Αιχμών - ΤΝΔΑ χρησιμοποιούν τις ίδιες υπολογιστικές αρχές, οι οποίες είναι υπεύθυνες για τη δημιουργία των χωροχρονικών δεδομένων.

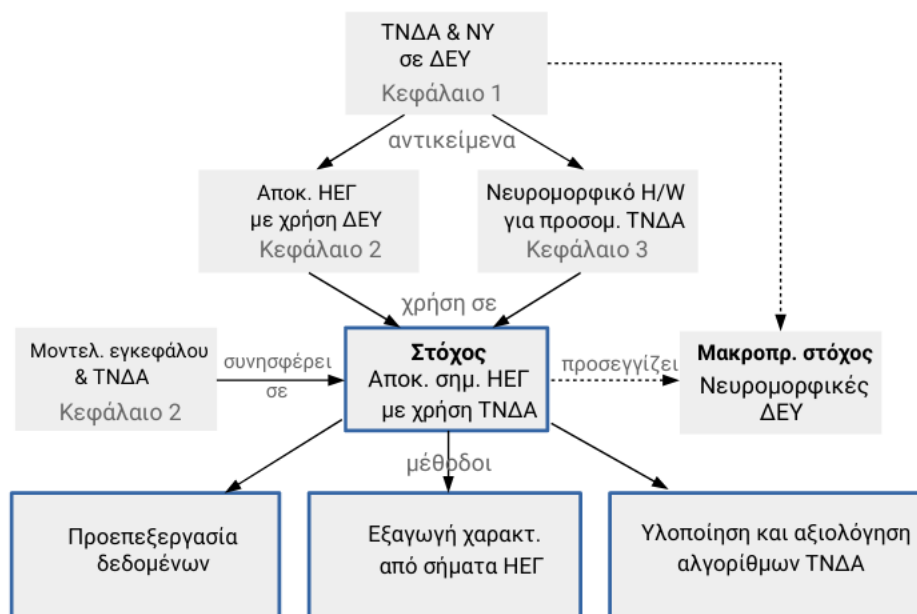
Μια σημαντική τρέχουσα πρόκληση, λοιπόν, έγκειται στον εντοπισμό και την εφαρμογή αλγορίθμων εμπνευσμένων από την εγκεφαλική λειτουργία για την αποκωδικοποίηση των καταγεγραμμένων εγκεφαλικών σημάτων. Παράλληλα, η Νευρομορφική Υπολογιστική φαίνεται ότι επιτρέπει την εφαρμογή σε πραγματικό χρόνο νευρομορφικών μοντέλων μεγάλης κλίμακας για επεξεργασία και υπολογισμό σε μη επεμβατικές ΔΕΥ. Οι στόχοι αλληλοσυμπληρώνονται. Η δημιουργία μιας πιο αποδοτικής Διεπαφής Εγκεφάλου-Υπολογιστή απαιτεί καλύτερους βιολογικά εμπνευσμένους αλγορίθμους και η προσομοίωση εγκεφαλικών δραστηριοτήτων σε μεγάλη κλίμακα και σε πραγματικό χρόνο είναι εφικτή μόνο σε μαζικά παράλληλα νευρομορφικά υπολογιστικά συστήματα.

Σε αυτή την εργασία θα εστιάσουμε σε μη-επεμβατικές ΔΕΥ που κάνουν χρήση Ηλεκτροεγκεφαλογραφήματος για την αποκωδικοποίηση κινήσεων νοερής απεικόνισης (motor imagery) του αριστερού και του δεξιού χεριού με στόχο τον έλεγχο ενός ρομποτικού βραχίονα ή προσθετικού χεριού. Το βασικό μέρος μιας διεπαφής εγκεφάλου-υπολογιστή είναι η αποκωδικοποίηση των νευρωνικών σημάτων και ο προσδιορισμός της υποκείμενης πρόθεσης. Για την ταξινόμηση, θα εφαρμόσουμε και θα αναπτύξουμε περαιτέρω, την προσέγγιση των Tayeb et al. [99], οι οποίοι έκαναν χρήση ενός Νευρωνικού Δικτύου Αιχμών που βασίζεται στο οσφρητικό σύστημα εντόμων [91] για την αποκωδικοποίηση κινήσεων νοερής απεικόνισης από σήματα ΗΕΓ. Το παραπάνω νευρωνικό δίκτυο θα υλοποιηθεί στην νευρομορφική υπολογιστική πλατφόρμα SpiNNaker [22], η οποία επιτρέπει την ανάπτυξη προσομοιώσεων υψηλής παραλληλίας και χαμηλής ισχύος Νευρωνικών Δικτύων Αιχμών μεγάλης κλίμακας.

1.6 Ερευνητικά Ερωτήματα

Μία καλά δομημένη έρευνα θεωρείται ελλιπής χωρίς να προσπαθεί να απαντήσει σε συγκεκριμένες ερευνητικές ερωτήσεις. Είναι τα ερωτήματα που ένας ερευνητής συλλογίζεται, τα οποία κατευθύνουν την διαδικασία της έρευνας. Αυτή η εργασία θέτει ορισμένες ερωτήσεις, και ενώ κάποιες πρόκειται να απαντηθούν, άλλες είναι, πιθανώς, ευκαιρίες για μελλοντική έρευνα. Ερωτήματα για τα οποία γίνεται προσπάθεια να απαντηθούν είναι τα ακόλουθα:

- Πως μπορούμε να μετατρέψουμε σκέψεις σε κατανοητές από μία μηχανή εντολές, οι οποίες θα μπορούν να χρησιμοποιηθούν για την εκτέλεση ορισμένων μηχανικών πράξεων, όπως η κίνηση ενός μηχανικού βραχίονα;
- Ποίοι είναι οι διαφορετικοί αλγόριθμοι που χρησιμοποιούνται σήμερα από την επιστημονική κοινότητα για την εκτέλεση κινήσεων μέσω ΔΕΥ και κατα πόσο επιδέχονται βελτίωση;
- Πως μπορεί η χρήση νευρομορφικών υπολογιστικών μοντέλων και συστημάτων, όπως τα νευρωνικά δίκτυα αιχμών, να βελτιώσει την ικανότητα ταξινόμησης κινήσεων νοερής απεικόνισης, συγκριτικά με state-of-the-art αλγορίθμους μηχανικής μάθησης;



Σχήμα 1.1: Διάρθρωση της εργασίας.

Ερωτήσεις που πιθανώς να μπορούν να λυθούν σε μελλοντική έρευνα:

- Μπορούν οι ΔΕΥ να γεφυρώσουν το φυσικό και νοητικό χάσμα που υπάρχει ανάμεσα στους ανθρώπους και την τεχνητή νοημοσύνη;
- Πως μπορούν να χρησιμοποιηθούν τεχνικές Μεταφοράς Μάθησης (Transfer Learning) στην χρήση διεπαφών μεταξύ ανθρώπου και μηχανών, ώστε να μειωθεί ο χρόνος εκπαίδευσης ενός συστήματος, εξαιτίας της μοναδικότητας των νευρικών σημάτων κάθε υποκειμένου;

1.7 Διάρθρωση Εργασίας

Η παρούσα Διπλωματική Εργασία οργανώνεται σε 7 κεφάλαια. Στο Κεφάλαιο 1 γίνεται μία εισαγωγή στην προέλευση και το κίνητρο της έρευνας, δηλώνεται το προς επίλυση πρόβλημα, καθορίζονται τα ερευνητικά ερωτήματα που κατευθύνουν την ερευνητική προσπάθεια, ενώ σκιαγραφείται και η δομή της Εργασίας. Στο Κεφάλαιο 2 καλύπτεται το θεωρητικό υπόβαθρο που απαιτείται ώστε να είναι δυνατή η κατανόηση της αρχιτεκτονικής του συστήματος που πρόκειται να υλοποιηθεί αργότερα και η ερμηνεία των αποτελεσμάτων. Στο Κεφάλαιο 3 υπάρχει μία σύντομη ανάλυση των προγραμματιστικών εργαλείων και τεχνολογιών που χρησιμοποιούνται για την υλοποίηση του συστήματος. Το Κεφάλαιο 4 παρέχει μία γρήγορη βιβλιογραφική επισκόπηση των πιο πρόσφατων ερευνητικών δημοσιεύσεων και εργασιών στο επιστημονικό πεδίο που εξετάζεται. Στο Κεφάλαιο 5 παρέχεται μία υψηλού επιπέδου περιγραφή της αρχιτεκτονικής του συστήματος που θα υλοποιηθεί, ενώ στο Κεφάλαιο 6 αναλύονται σε βάθος τόσο οι μέθοδοι και οι αλγόριθμοι που χρησιμοποιήθηκαν, όσο και τα αποτελέσματα που προέκυψαν από την πειραματική διαδικασία. Το Κεφάλαιο 7 ολοκληρώνει την παρούσα εργασία με ορισμένες κατευθύνσεις τις οποίες θα μπορούσαν να ακολουθήσουν μελλοντικές μελέτες και απόψεις σχετικά με το ευρύτερο επιστημονικό πεδίο.

Κεφάλαιο 2

Θεωρητικό Υπόβαθρο

“As engineers, we would be foolish to ignore the lessons of a billion years of evolution.”

— Carver Mead


2.1 Βασικές Αρχές Διεπαφών Εγκεφάλου-Υπολογιστή

Μία Διεπαφή Εγκεφάλου-Υπολογιστή είναι ένα κανάλι επικοινωνίας και ελέγχου που καταγράφει εγκεφαλικά σήματα, τα αναλύει και τα μεταφράζει σε εντολές που μεταδίδονται σε μια συσκευή εξόδου ώστε να πραγματοποιηθεί μια επιθυμητή ενέργεια [93] και δεν εξαρτάται με οποιοδήποτε τρόπο από τις φυσιολογικές οδούς εξόδου του εγκεφάλου [68]. Είναι σημαντικό να τονιστεί εδώ πως η ανάλυση των εγκεφαλικών σημάτων απαιτεί επαρκής γνώση της εσωτερικής λειτουργίας του ανθρώπινου εγκεφάλου. Σε αυτή την ενότητα παρέχεται μία επισκόπηση των δομών του εγκεφάλου και του τρόπου με τον οποίο μπορεί να πραγματοποιηθεί η απόκτηση των εγκεφαλικών σημάτων, καθώς και πως αυτά τα δεδομένα μπορούν να ερμηνευτούν [4, 66].

2.1.1 Δομή του εγκεφάλου και απόκτηση εγκεφαλικών σημάτων

Ο ανθρώπινος εγκέφαλος χωρίζεται σε τρία μέρη: το εγκεφαλικό στέλεχος (brain stem), την παρεγκεφαλίδα (cerebellum) και τον άνω εγκέφαλο (cerebrum). Το άνω και μεγαλύτερο μέρος του εγκεφάλου χωρίζεται σε δύο ημισφαίρια: το αριστερό και το δεξί. Η επιφάνεια του άνω εγκεφάλου ονομάζεται φλοιός (cortex) και χωρίζεται σε τέσσερις ζώνες που ονομάζονται λοβοί (βλέπε Σχήμα 2.1). Ο μετωπικός (frontal) λοβός χρησιμοποιείται σε γνωστικές λειτουργίες, όπως η ομιλία, οι κινήσεις αλλά και άλλες εκτελεστικές λειτουργίες. Ο κροταφικός (temporal) λοβός συμμετέχει σε ακουστικές, οπτικές και γλωσσικές λειτουργίες, ενώ χρησιμοποιείται και για συναισθηματική επεξεργασία. Ο βρεγματικός (parietal) λοβός λαμβάνει μέρος σε διαδικασίες όπως η ανάγνωση, η γραφή, η κατανόηση γλώσσας, η προσοχή και η χωρική αντίληψη. Τέλος, ο ινιακός (occipital) λοβός συμμετέχει ενεργά στην επεξεργασία οπτικών ερεθισμάτων [32].

Η καταγραφή της εγκεφαλικής δραστηριότητας μπορεί να επιτευχθεί χρησιμοποιώντας ηλεκτρικά πεδία, μαγνητικά πεδία ή αρτηριακή πίεση. Η συλλογή εγκεφαλικών σημάτων μπορεί να γίνει με τη βοήθεια επεμβατικών ή μη επεμβατικών μεθόδων, ανάλογα με την περιοχή τοποθέτησης της συσκευής μέτρησης; στους εγκεφαλικούς ιστούς ή στο τριχωτό της κεφαλής. Με την ίδια λογική, μία Διεπαφή Εγκεφάλου-Υπολογιστή μπορεί να ονομαστεί επεμβατική ή μη-επεμβατική [68]. Τα επεμβατικά συστήματα είναι λιγότερο επιρρεπή στον θόρυβο συγκριτικά με τις μη-επεμβατικές διεπαφές, αλλά χρειάζονται χειρουργική επέμβαση για την τοποθέτηση στον χρήστη, ενώ θα πρέπει να αφαιρεθούν ή να αντικατασταθούν μετά από ένα ορισμένο χρονικό διάστημα εάν εμφανιστεί



Σχήμα 2.1: Πλευρική όψη των λοβών του ανθρώπινου εγκεφάλου [32].

το φαινόμενο της απόρριψης της συσκευής από τους ιστούς. Ακόμα, ενώ οι επεμβατικές ΔΕΥ χρησιμοποιούν κυρίως Ηλεκτροφλοιογράφημα (Electrocorticography-ECoG) [56], οι μη-επεμβατικές ΔΕΥ κάνουν χρήση διαφόρων μεθόδων: Ηλεκτροεγκεφαλογράφημα [74], Φασματοσκοπία Υπερύθρου [10], Μαγνητοεγκεφαλογράφημα [34] και Λειτουργική Απεικόνιση Μαγνητικού Συντονισμού [75]. Κάθε προσέγγιση διαφέρει ως προς το κόστος, την αποτελεσματικότητα αλλά και την φορητότητα. Πολλές είναι οι ΔΕΥ που χρησιμοποιούν ΗΕΓ λόγω της ευκολίας χρήσης του, καθώς και του χαμηλού κόστους σε σύγκριση με συσκευές μαγνητοεγκεφαλογραφίας ή απεικόνισης μαγνητικού συντονισμού. Το ΗΕΓ χρησιμοποιεί ενεργά ή παθητικά ηλεκτρόδια τα οποία τοποθετούνται στο τριχωτό της κεφαλής για τη συλλογή ηλεκτρικών δυναμικών που παράγονται από τον εγκέφαλο [74].


Είναι γεγονός πως στις ιατρικές εφαρμογές των μη-επεμβατικών ΔΕΥ χρησιμοποιείται συχνότερα το ΗΕΓ. Τα BrainAmp¹ και g.USBamp² αποτελούν δύο παραδείγματα ιατρικών ενισχυτών ΗΕΓ, που συνδυάζονται με κατάλληλα ηλεκτρόδια για την καταγραφή εγκεφαλικών σημάτων. Παράλληλα, τα τελευταία χρόνια έχουν αρχίσει να εμφανίζονται μη-ιατρικές χρήσεις ΔΕΥ που βασίζονται σε σήματα ΗΕΓ σε τομείς όπως η ψυχαγωγία και τα βιντεοπαιχνίδια. Για το λόγο αυτό έχουν αναπτυχθεί νέες τεχνολογίες καταγραφής ΗΕΓ, με μικρότερο κόστος, όπως το Emotiv EPOC³. Στην έρευνά τους, οι Duvina et al. [19] σύγκριναν την ικανότητα ταξινόμησης σημάτων ΗΕΓ μιας συσκευής καταγραφής ΗΕΓ ιατρικής χρήσης ονόματι ANT με την συσκευή γενικού σκοπού EPOC. Όπως ήταν αναμενόμενο βρήκαν πως το ιατρικό σύστημα έχει καλύτερα αποτελέσματα στο δοσμένο πρόβλημα. Ωστόσο, οι συγγραφείς βρήκαν το EPOC να είναι κατάλληλο για μη κρίσιμες εφαρμογές, όπως τα βιντεοπαιχνίδια, δείχνοντας αξιόλογη απόδοση στις εργασίες ταξινόμησης.

Όπως αναφέραμε, οι συσκευές καταγραφής ΗΕΓ ουσιαστικά λαμβάνουν τα ηλεκτρικά πεδία που εκπέμπουν οι νευρώνες του εγκεφάλου [74] μέσω των ηλεκτροδίων τα οποία παράγουν ένα σήμα ασθενούς πλάτους. Τα ηλεκτρόδια που χρησιμοποιούνται στο ΗΕΓ τοποθετούνται στην επιφάνεια του τριχωτού της κεφαλής, συνήθως με τη βοήθεια ενός μικρού σκουφιδιού. Επίσης, γίνεται χρήση τζελ ή αλατισμένου νερού με σκοπό την αύξηση της αγωγιμότητας μεταξύ του κεφαλιού και των ηλεκτροδίων. Αυτό φυσικά σημαίνει πως απαιτείται ένα δεδομένο χρονικό διάστημα, συνήθως 20 λεπτά, για το στήσιμο ενός συστήματος καταγραφής ΗΕΓ. Τα ηλεκτρόδια συνηθίζεται να τοποθετούνται στο κεφάλι με βάση το καθιερωμένο σύστημα τοποθέτησης 10-20 (βλέπε Σχήμα

¹<https://www.brainproducts.com/productdetails.php?id=7>

²<https://www.gtec.at/product/g-usbamp-research/>

³<http://www.emotiv.com/epoc/>



Σχήμα 2.2: Διεθνές σύστημα τοποθέτησης ηλεκτροδίων 10/20 [21].

2.2).

Επιπρόσθετα, το Ηλεκτροεγκεφαλογράφημα έχει αρκετά καλή χρονική ανάλυση, της τάξης των των χιλιοστών του δευτερολέπτου, συγκριτικά με άλλες μεθόδους όπως η Λειτουργική Απεικόνιση Μαγνητικού Συντονισμού (ΛΑΜΣ) ή η Φασματοσκοπία Υπερύθρου, των οποίων η χρονική ανάλυση κυμαίνεται σε τιμές της τάξης των δευτερολέπτων. Ωστόσο, σε αντίθεση με τη ΛΑΜΣ, το ΗΕΓ έχει χειρότερη χωρική ανάλυση εξαιτίας της φύσης των ηλεκτρικών πεδίων και της διάχυσής τους. Ακόμα, είναι λογικό πως η επιφανειακή εγκεφαλική δραστηριότητα είναι σημαντικά πιο εύκολο να μετρηθεί σε σχέση με την εσωτερική. Παράλληλα, το ΗΕΓ απαιτεί μία μη αμελητέα ανάλυση των καταγεγραμμένων σημάτων, εξαιτίας του χαμηλού σηματοθορυβικού λόγου που προκαλείται από την μυϊκή δραστηριότητα [62].

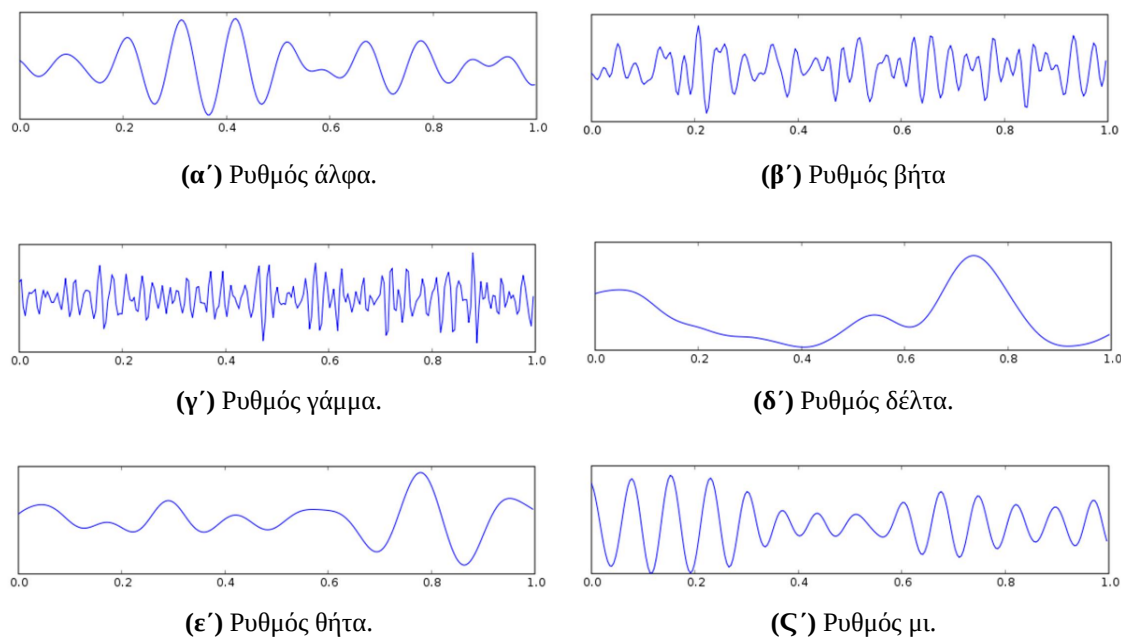
2.1.2 Συνήθεις δείκτες ΗΕΓ σε Διεπαφές Εγκεφάλου - Υπολογιστή

Οι δείκτες ΗΕΓ είναι παραλλαγές του σήματος που λαμβάνεται από τα εγκεφαλικά δεδομένα, ενώ η επεξεργασία τους αποτελεί κύριο συστατικό μιας ΔΕΥ. Οι πιο συνηθισμένοι δείκτες που χρησιμοποιούνται σε εφαρμογές ΔΕΥ πρόκειται να αναλυθούν στις παρακάτω ενότητες.

Ρυθμοί Ηλεκτροεγκεφαλογραφήματος

Οι ρυθμοί ή κύματα του ΗΕΓ είναι ταλαντώσεις οι οποίες μπορούν να παρατηρηθούν σε συγκεκριμένες περιοχές του εγκεφάλου και σε δεδομένες ζώνες συχνοτήτων. Προσφέρουν πληροφορίες σχετικά με την ψυχική κατάσταση του υποκειμένου και μπορούν ελεγχθούν οικειοθελώς [73]. Το ΗΕΓ αποκαλύπτει 4 βασικά κύματα: άλφα, βήτα, γάμμα, δέλτα, θήτα και μι.

- **Ρυθμός άλφα:** Ο ρυθμός α κυμαίνεται μεταξύ των συχνοτήτων 8-13 Hz και μπορεί να βρεθεί στο οπίσθιο (ινιακό) μέρος του εγκεφάλου, ενώ είναι υψηλότερος στη μη κυρίαρχη πλευρά κάθε ατόμου. Παρατηρείται κυρίως με το κλείσιμο των ματιών ή σε καταστάσεις ηρεμίας, μιας και υψηλότερα επίπεδα εγρήγορσης προκαλούν αύξηση του πλάτους του.



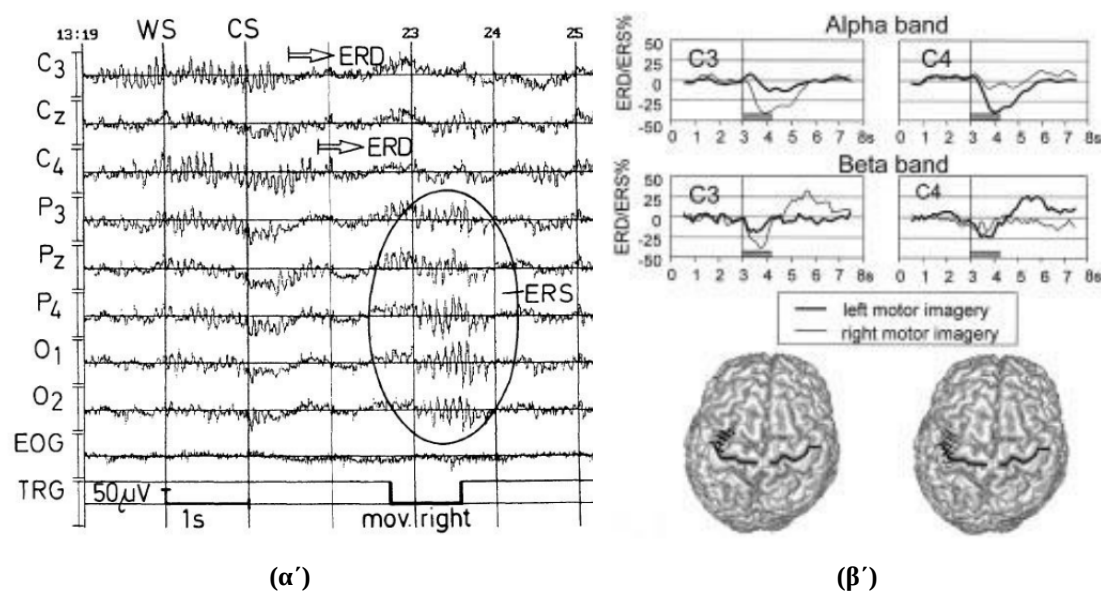
Σχήμα 2.3: Φιλτραρισμένες καταγραφές ΗΕΓ από το ηλεκτρόδιο Oz, οι οποίες αναπαριστούν τους ρυθμούς ΗΕΓ (αναπαραγωγή από Hugo Gambo⁴).

- **Ρυθμός βήτα:** Ο ρυθμός β κυμαίνεται μεταξύ των συχνοτήτων 13-30 Hz και μπορεί να ανιχνευθεί όταν ο χρήστης είναι ξύπνιος και έχει τη συνείδησή του, ενώ επηρεάζεται άμεσα από τις κινήσεις του.
- **Ρυθμός γάμμα:** Ο ρυθμός γ εμφανίζεται σε συχνότητες μεγαλύτερες των 30 Hz και συνδέεται με γνωστικές και κινητικές δραστηριότητες, ενώ η μέτρησή του με τη χρήση επιφανειακού ΗΕΓ είναι αρκετά δύσκολη.
- **Ρυθμός δέλτα:** Ο ρυθμός δ κυμαίνεται μεταξύ των συχνοτήτων 1-4 Hz και παρατηρείται κυρίως στους ενήλικες κατά τη διάρκεια του ύπνου.
- **Ρυθμός θήτα:** Ο ρυθμός θ κυμαίνεται μεταξύ των συχνοτήτων 4-8 Hz και μπορεί να βρεθεί σε μικρά παιδιά κατά τη διάρκεια υπνηλίας ή ζάλης, ενώ είναι γνωστό πως σχηματίζει μία αιχμή (spike) όταν ο χρήστης προσπαθεί να καταστείλει κάποια δράση ή απόκριση [25].
- **Ρυθμός μι:** Ο ρυθμός μ κυμαίνεται μεταξύ των συχνοτήτων 8-13 Hz και συνδέεται με κινησιολογικές δραστηριότητες, όπως η κίνηση των χεριών [108].

Δυναμικά βασισμένα σε γεγονότα

Έχει παρατηρηθεί πως ορισμένα γεγονότα όπως τα αισθητηριακά ερεθίσματα, η κινητική δραστηριότητα και οι εργασίες μνήμης επιδρούν άμεσα στους ρυθμούς που αναλύσαμε στην προηγούμενη ενότητα [80]. Όταν υπάρχει αύξηση της ρυθμικής δραστηριότητας λέμε πως έχουμε συγχρονισμό που συσχετίζεται με γεγονότα (Event-Related Synchronization) και συνδέεται με την κατάσταση νοητικής χαλάρωσης του υπό εξέταση υποκείμενου ή μετά την εκτέλεση μιας πράξης,

⁴https://commons.wikimedia.org/wiki/File:Eeg_raw.svg, Creative Commons License



Σχήμα 2.4: Καταγραφές της εγκεφαλικής δραστηριότητας. (α') Δεδομένα ΗΕΓ καταγεγραμμένα κατά τη διάρκεια της κίνησης ενός δακτύλου του δεξιού χεριού αναδεικνύοντας καταστάσεις συγχρονισμού και αποσυγχρονισμού. Μία ένδειξη ερεθίσματος (Cue Stimulus - CS) ακολουθεί ένα προειδοποιητικό σήμα (Warning Signal - WS) υποδεικνύοντας την πλευρά (δεξιά ή αριστερή) της κίνησης που πρόκειται να εκτελεστεί [79]. (β') Παραλλαγές στις ζώνες συχνότητας των ρυθμών άλφα και βήτα κατά τη διάρκεια κινητικών κινήσεων [81].

ενώ με αντίστοιχη μείωση λέμε πως έχουμε αποσυγχρονισμό που συσχετίζεται με γεγονότα (Event-Related Desynchronization). Αποσυγχρονισμό μπορεί να συναντήσουμε όταν το υποκείμενο φαντάζεται πως εκτελεί μια κίνηση ή λίγα χιλιοστά του δευτερολέπτου πριν από την εκτέλεσή της (βλέπε Σχήμα 2.4). Για παράδειγμα, η σκέψη για την κίνηση του δεξιού χεριού θα πυροδοτήσει τον αποσυγχρονισμό των ρυθμών μι και βήτα στον αριστερό κινητικό φλοιό.

Ο αποσυγχρονισμός που βασίζεται σε γεγονότα, δηλαδή δηλαδή η μείωση των εγκεφαλικών ρυθμών σε συγκεκριμένες μπάντες συχνότητας, χρησιμοποιείται σε εργασίες νοητικής κίνησης, οι οποίες κυρίως βασίζονται στους ρυθμούς άλφα και βήτα. Σημειώνεται πως η νοητική κίνηση αναπαριστά την νοητική ή φανταστική κινητική δραστηριότητα και διαφέρει από την πραγματική κινητική δραστηριότητα που πρόκειται να εκτελεστεί. Έπειτα από την εκτέλεση ή την σκέψη για την εκτέλεση μιας κίνησης, μπορούν να παρατηρηθούν τα επονομαζόμενα αναπήδησης (rebound) των ρυθμών άλφα και βήτα (βλέπε Σχήμα 2.4). Όπως θα δούμε, οι νοητικές κινήσεις επιτρέπουν στους χρήστες να δώσουν εντολές σε μία ΔΕΥ απλά με το να φαντάζονται ότι πράττουν μία κίνηση [81].

Η P300 είναι μία θετική κυματομορφή η οποία εμφανίζεται περίπου 300 χιλιοστά του δευτερολέπτου μετά από την εμφάνιση ενός σχετικού ερεθίσματος [18]. Το μοτίβο P300 χρησιμοποιείται συχνά σε συνδυασμό με ένα πλέγμα από γράμματα στο μη επεμβατικό σύστημα του Ορθογράφου P300 [53]. Στο συγκεκριμένο πείραμα παρουσιάζεται στον χρήστη ένας πίνακας χαρακτήρων 6 επί 6 (βλέπε Σχήμα 2.5). Η αποστολή του χρήστη είναι να δώσει προσοχή σε χαρακτήρες μιας λέξης που έχει καθοριστεί από τον ερευνητή (ένας χαρακτήρας κάθε φορά). Όλες οι γραμμές και οι στήλες του πίνακα ανάβουν τυχαία και διαδοχικά με ρυθμό 5.7 Hz. Δύο από τις 12 φορές θα ανάψει μια στήλη ή γραμμή που θα περιέχει τον επιθυμητό χαρακτήρα. Το σύστημα καταγράφει τις κυματομορφές του χρήστη και βασιζόμενο στην κυματομορφή P300 αναγνωρίζει το γράμμα


DICE (D)					
A	B	C	D	E	F
G	H	I	J	K	L
M	N	O	P	Q	R
S	T	U	V	W	X
Y	Z	1	2	3	4
5	6	7	8	9	_

Σχήμα 2.5: Το πλέγμα γραμμάτων του Ορθογράφου P300 [53].


στο οποίο έδωσε έμφαση. Αυτό το σύστημα έχει εφαρμοστεί επιτυχώς σε παραπληγικούς ασθενείς, επιτρέποντάς τους να επικοινωνήσουν μόνο με τις σκέψεις τους [42].

Καταστάσεις χαλάρωσης και συγκέντρωσης

Μία διεπαφή εγκεφάλου-υπολογιστή μπορεί ακόμα να χρησιμοποιηθεί για την μέτρηση της νοητικής κατάστασης ενός ατόμου. Για παράδειγμα, οι George et al. σχεδίασαν ένα σύστημα που τους επιτρέπει να μετρούν τα επίπεδα συγκέντρωσης και χαλάρωσης [27]. Αυτά τα επίπεδα μπορούν να υπολογιστούν με τη βοήθεια των λόγων των ρυθμών άλφα, βήτα και θήτα [59, 72, 39]. Μία εναλλακτική μέθοδος χρησιμοποιεί τεχνικές μηχανικής μάθησης για να ταξινομήσει αυτές τις δύο νοητικές καταστάσεις [33]. Οι George et al. σύγκριναν αυτές τις δύο διαφορετικές μεθόδους και βρήκαν πως αυτή που βασίζεται στην μηχανική μάθηση έχει σημαντικά υψηλότερη απόδοση [27]. Η μελέτη τους βασιζόταν σε ένα δισδιάστατο περιβάλλον που μοιάζει με βιντεοπαιχνίδι, στο οποίο οι συμμετέχοντες κατευθύνουν ένα αεροπλάνο πάνω ή κάτω ανάλογα με την νοητική τους κατάσταση (βλέπε Σχήμα 2.6).



(α') Κατάσταση ηρεμίας.



(β') Κατάσταση συγκέντρωσης.

Σχήμα 2.6: 2Δ εφαρμογή ΔΕΥ η οποία υποδεικνύει την νοητική κατάσταση του χρήστη.

2.2 Ανίχνευση νοητικών κινήσεων μέσω ΗΕΓ

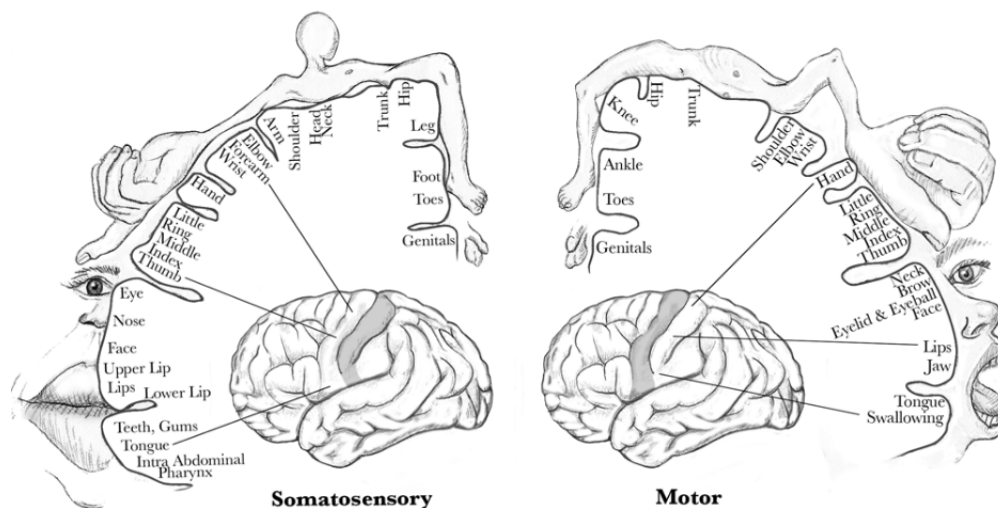
Για την διεπαφή που θα αναπτύξουμε σε αυτή την εργασία θα χρησιμοποιήσουμε μετρήσεις μη επεμβατικού ΗΕΓ για την ανάλυση της εγκεφαλικής δραστηριότητας. Θυμίζουμε πως ο σκοπός μιας ΔΕΥ είναι είτε ο καθορισμός της πρόθεσης ή της νοητικής κατάστασης ενός ατόμου παρακολουθώντας την εγκεφαλική του δραστηριότητα, είτε η παροχή ενός νέου καναλιού εξόδου του εγκεφάλου το οποίο απαιτεί εκούσιο προσαρμοστικό έλεγχο από τον χρήστη. Συγκεκριμένα, στην περίπτωση χρήσης ΔΕΥ για την αποκωδικοποίηση νοητικών κινήσεων, τα υποκείμενα εκτελούν νοητικές εργασίες, οι οποίες προκαλούν αλλαγές στους ρυθμούς του ΗΕΓ.

2.2.1 Χαρακτηριστικά σημάτων ΗΕΓ που αντιστοιχούν σε νοητικές κινήσεις

Δεδομένου ότι όλες οι ΔΕΥ λειτουργούν με βάση τα ορατά αποτελέσματα της εγκεφαλικής δραστηριότητας, μπορούν να ανιχνεύσουν μόνο νευρωνικά δυναμικά μεγάλης κλίμακας της τάξης των 50.000 και παραπάνω συγχρονισμένων νευρώνων, χρησιμοποιώντας το σύστημα 10-20 [52]. Τα μετρούμενα αυτά γεγονότα έχουν συνήθως τη μορφή διαδοχικών νευρωνικών διεργασιών οι οποίες ενεργοποιούνται είτε από εξωτερικά (ερεθίσματα) ή από εσωτερικά γεγονότα (πρόθεση). Κατα τη διάρκεια καταγραφής σημάτων ΗΕΓ από συνειδητά ελεγχόμενη εγκεφαλική δραστηριότητα, είναι πιθανό να μην γίνει σωστή ανίχνευση της αιτίας. Οι λόγοι ποικίλουν, από την αλληλοεξουδετέρωση των ηλεκτρομαγνητικών πεδίων έως την σκέδασή τους, με αποτέλεσμα το τελικό ηλεκτρομαγνητικό πεδίο να είναι πολύ αδύναμο για να ανιχνευθεί. Συνεπώς παρατηρούνται συχνά χωρικά συμπαγή πεδία γιατί είναι πιο πιθανό να είναι συντονισμένα τα νευρωνικά δίκτυα που τα παράγουν. Έτσι, δεν είναι σίγουρο πως τα παρατηρούμενα σήματα αντιστοιχούν άμεσα στην συνειδητά ελεγχόμενη εγκεφαλική δραστηριότητα. Για να αυξηθεί η πιθανότητα ανίχνευσης των σωστών μοτίβων που αντιστοιχούν στην υπό εκτέλεση νοητική κίνηση, μπορούμε να εκμεταλλευτούμε ορισμένα χωρικά και χρονικά χαρακτηριστικά των σημάτων του ΗΕΓ, τα οποία θα αναφέρουμε παρακάτω.

Τα χωρικά χαρακτηριστικά είναι σημαντικά για τον καθορισμό της τοποθέτησης των ηλεκτροδίων. Δεδομένου ότι διεργασίες πίσω από τις νοητικές κινήσεις λαμβάνουν χώρα στον αισθητηριακό-κινητικό φλοιό (sensorimotor cortex), τα ηλεκτρόδια που τοποθετούνται εκεί έχουν την υψηλότερη πιθανότητα να ανιχνεύσουν τα νοητικά μοτίβα που αντιστοιχούν σε νοητικές κινήσεις, όπως για παράδειγμα κινήσεις του δεξιού και του αριστερού χεριού. Στο Σχήμα 2.7 φαίνονται οι διαφορετικές περιοχές του φλοιού και οι αντίστοιχες λειτουργίες τους

Όπως είδαμε και σε προηγούμενη ενότητα τα χρονικά χαρακτηριστικά ενός σήματος ΗΕΓ μπορούν να διαιρεθούν περαιτέρω σε δυναμικά και ταλαντωτικές διεργασίες διαφορετικών ζωνών συχνοτήτων, τα οποία έχουν σαν στόχο την δημιουργία μοτίβων που είναι εύκολα αναγνωρίσιμα από τις θορυβώδεις καταγραφές του ΗΕΓ. Για την εύρεση προτύπων που αντιστοιχούν σε νοητικές κινήσεις, οι ζώνες των κυματομορφών άλφα (9-12 Hz) και βήτα (12-25 Hz) παρέχουν ένα εύρος συχνοτήτων στο οποίο τα συγχρονισμένα μοτίβα ενεργοποίησης των νευρώνων στον κινητικό φλοιό μπορούν να ανιχνευθούν. Δεδομένου ότι η εγκεφαλική δραστηριότητα μπορεί να ποικίλει μεταξύ των διαφορετικών υποκειμένων, αλλά και των διαφορετικών χρόνων καταγραφής, οι συγκεκριμένες συχνότητες αυτών των ταλαντωτικών διεργασιών μπορούν επίσης να διαφέρουν. Για την δημιουργία αναπαραστάσεων των νοητικών διαδικασιών που είναι ανεξάρτητες ως προς το άτομο και τον χρόνο καταγραφής, τα δυναμικά που βασίζονται στα γεγονότα υπολογίζονται κατά μέσο όρο, καθιστώντας τα (ιδανικά) μεταβιβάσιμα μεταξύ διαφορετικών συνεδριάσεων και υποκειμένων.



Σχήμα 2.7: Οι δομές του σωματοαισθητηριακού και του κινητικού φλοιού, μαζί με τις αντίστοιχες λειτουργίες τους.⁵

2.2.2 Καταγραφή δεδομένων νοητικών κινήσεων μέσω ΗΕΓ


Οι νοητικές κινήσεις ή αλλιώς οι νοητικές προσομοιώσεις κινητικών δράσεων, δημιουργούν μοτίβα νευρωνικών ενεργοποιήσεων τα οποία εκτείνονται και στα δύο ημισφαίρια του εγκεφάλου. Όπως έχουμε ήδη αναφέρει, η παρακολούθηση της ηλεκτρικής δραστηριότητας του εγκεφάλου μπορεί να γίνει με τη χρήση ηλεκτροδίων στις θέσεις που ορίζει το διεθνές σύστημα 10-20. Έτσι, για την καταγραφή σημάτων που αντιστοιχούν σε νοητικές κινήσεις του αριστερού και του δεξιού χεριού αρκούν τα ηλεκτρόδια με ετικέτες C3, C4 και CZ (βλέπε Σχήμα 2.2), καθώς καλύπτουν τα περισσότερα μέρη του κινητικού φλοιού [36].

Για την υλοποίηση μίας ΔΕΥ η οποία ανιχνεύει νοητικές κινήσεις του αριστερού και δεξιού χεριού, πρόκειται να χρησιμοποιήσουμε ορισμένα σύνολα δεδομένων τα οποία παρέχονται από το Πανεπιστήμιο του Γκρατς [55]. Αναλυτική παρουσίαση των δεδομένων γίνεται στο Κεφάλαιο 5. Τα δεδομένα αποτελούνται από διάφορες συνεδρίες καταγραφής ΗΕΓ, με την κάθε μία από αυτές να περιλαμβάνει τυπικά 120 δοκιμές (βλέπε Σχήμα 2.8). Κάθε δοκιμή ξεκινάει με μία περίοδο χαλάρωσης, κατά την οποία δεν λαμβάνει χώρα κάποια νοητική κίνηση. Έπειτα από λίγα δευτερόλεπτα, μία τυχαία ένδειξη προβάλλεται στο υποκείμενο και αμέσως μετά πρέπει να φανταστεί ότι κινεί το δεξί ή το αριστερό του χέρι ανάλογα με την προβαλλόμενη ένδειξη. Μετά την εκτέλεση της νοητικής κίνησης, τυπικά 4 με 5 δευτερόλεπτα, η περίοδος χαλάρωσης και η προετοιμασία για την επόμενη δοκιμή ξεκινούν. Δεδομένου ότι οι νοητικές κινήσεις είναι αρκετά κουραστικές για το υποκείμενο δεν μπορούν να διεξαχθούν πάνω από 120 δοκιμές χωρίς την απώλεια ποιότητας στα καταγεγραμμένα σήματα

2.3 Νευρωνικά Δίκτυα Αιχμών

Υπο το πρίσμα της παράκαμψης των απλοποιητικών παραδοχών και γενικεύσεων των υφιστάμενων τεχνολογιών Νευρωνικών Δικτύων 1ης γενιάς και υποκινούμενη από την επιθυμία της καλύτερης κατανόησης των αληθινών δυνατοτήτων επεξεργασίας των νευρωνικών πληροφοριών, σε συνδυασμό με τη συνεχή αύξηση των δυνατοτήτων των υπολογιστικών συστημάτων στη διάθεση πόρων, η επιστημονική κοινότητα έχει αναπτύξει πολύπλοκα βιολογικά μαθηματικά μοντέλα,

⁵<https://www.ebmconsult.com/articles/homunculus-sensory-motor-cortex>



Σχήμα 2.8: Δοκιμή μιας τυπικής συνεδρίας καταγραφής νοητικών κινήσεων [55].

τα οποία ονομάζονται (Τεχνητά) Νευρωνικά Δίκτυα Αιχμών - ΝΔΑ (Spiking Neural Networks - SNN) και στοχεύουν στην προσομοίωση με τον πλέον ρεαλιστικό τρόπο των πολύπλοκων δομών του ανθρώπινου εγκεφάλου και του τρόπου επεξεργασίας και μετάδοσης της νευρωνικής πληροφορίας [50]. Τα ΝΔΑ χρησιμοποιούν ακολουθίες αιχμών (spikes) σαν μηχανισμούς εσωτερικής παρουσίασης των πληροφοριών, σε αντίθεση με τις συνηθισμένες συνεχείς μεταβλητές, ενώ έχουν τουλάχιστον ισάξια εάν όχι καλύτερη απόδοση σε υπολογιστικό κόστος από τα παραδοσιακά Τεχνητά Νευρωνικά Δίκτυα - ΤΝΔ σε ορισμένες εφαρμογές [47]. Τα τελευταία χρόνια είναι πολλές οι μελέτες που χρησιμοποιούν τα ΝΔΑ σε πρακτικές εφαρμογές, τα αποτελέσματα των οποίων φαίνεται να είναι πολλά υποσχόμενα στην λύση αληθινών πολύπλοκων προβλημάτων.


Σε αυτή την ενότητα θα παρουσιάσουμε τα θεμελιώδη χαρακτηριστικά των ΝΔΑ και τα σημεία στα οποία αυτά διαφέρουν από τα παραδοσιακά τεχνητά νευρωνικά δίκτυα. Αρχικά, θα απεικονίσουμε τον τρόπο με τον οποίο οι βιολογικοί νευρώνες λειτουργούν και διαβιβάζουν σήματα μεταξύ τους. Έπειτα, θα παρουσιαστούν οι μαθηματικές αναπαραστάσεις των νευρωνικών δυναμικών που χρησιμοποιούν τα ΝΔΑ. Τέλος, θα γίνει μία εισαγωγή στα εργαλεία που χρησιμοποιούνται για την προσομοίωση αυτών των νευρωνικών δικτύων, είτε με τη χρήση κατάλληλου λογισμικού είτε με τη βοήθεια νευρομορφικού υλικού.

2.3.1 Νευροφυσιολογία του ανθρώπινου εγκεφάλου

Σε κυτταρικό επίπεδο, το κεντρικό νευρικό σύστημα αποτελείται από δύο τύπους κυττάρων: τους νευρώνες (neurons), τις στοιχειώδεις υπολογιστικές μονάδες του εγκεφάλου, και τα νευρογλοιακά κύτταρα, τις δομικές και μεταβολικές υποστηρικτικές κυτταρικές δομές. Εδώ θα εστιάσουμε στον πρώτο, δεδομένου ότι οι νευρώνες αποτελούν τα βασικά στοιχεία των υψηλότερων εγκεφαλικών λειτουργιών όπως η νόηση, η σκέψη και η δράση. Ο ανθρώπινος εγκέφαλος περιέχει περίπου εκατό δισεκατομμύρια (10^{11}) τέτοιες υπολογιστικές μονάδες και τέσσερις τάξεις μεγέθους περισσότερες συνδέσεις, τις συνάψεις (synapses) (10^{15}) [5]. Παρά τη μεγάλη πολυπλοκότητα και μέγεθός του ως όργανο, οι νευρώνες του εγκεφάλου καταφέρνουν να στέλνουν σήματα με μεγάλη ταχύτητα και ακρίβεια σε άλλα κύτταρα μέσω των συνάψεων, χάρη στην μορφολογία τους.

Νευρώνες

Ένας τυπικός νευρώνας αποτελείται από τρία λειτουργικά μέρη: τους δενδρίτες (dendrites), το κυτταρικό σώμα (cell body) και τον νευράξονα (axon) (βλέπε Σχήμα 2.9). Οι δενδρίτες ενός νευρώνα λαμβάνουν ερεθίσματα από άλλους νευρώνες και μεταδίδουν τα νευρωνικά σήματα στο σώμα του κυττάρου. Το σώμα αποτελεί το κύριο μέρος του νευρώνα και λειτουργεί ως ένας μη γραμμικός ρυθμιστής ο οποίος πυροδοτεί ένα εξερχόμενο σήμα όταν η συσσωρευμένη συνολική είσοδος σημάτων του νευρώνα ξεπερνάει ένα δεδομένο κατώφλι. Το εξερχόμενο σήμα διαδίδεται από τον εκφυτικό κώνο, το σημείο που ενώνει το σώμα με τον άξονα, κατά μήκος του νευράξονα σε άλλους νευρώνες. Οι περισσότεροι νευρώνες έχουν μόνο ένα άξονα, αλλά ενδεχομένως να συνδέονται με πολλούς νευρώνες μέσω των νευραξονικών απολήξεων [84].



Σχήμα 2.9: Λειτουργικά μέρη ενός βιολογικού νευρώνα. Ένα προσυναπτικό κύτταρο (a) συνδέεται με ένα μετασυναπτικό κύτταρο μέσω μίας (b) σύναψης και μεταφέρει το (c) δυναμικό δράσης στην κατεύθυνση που δείχνουν τα κόκκινα βέλη [84].

Η διάδοση των σημάτων από τον έναν νευρώνα στον άλλο συμβαίνει στην διασταύρωση των δύο αυτών νευρώνων, την σύναψη (Σχήμα 2.9). Η διάταξη είναι απλή: ένα προσυναπτικό κύτταρο (presynaptic cell) στέλνει ένα σήμα το οποίο λαμβάνεται από ένα άλλο μετασυναπτικό κύτταρο (postsynaptic cell).

Νευρωνικά σήματα

Τα νευρωνικά σήματα που διαδίδονται ανάμεσα στους νευρώνες είναι μικροί σε πλάτος και χρονική διάρκεια ηλεκτρικοί παλμοί, τα δυναμικά δράσης (action potentials). Το Σχήμα 2.9 (c) δείχνει την καταγραφή ενός δυναμικού δράσης όπως αυτό παρατηρήθηκε από τους Hodgkin and Huxley [40] στον νευράξονα ενός καλαμαριού. Ένα τυπικό δυναμικό δράσης, ή αλλιώς όπως συχνά αποκαλείται αιχμή (spike), έχει περίπου πλάτος 100 mV και διαρκεί 1-2 ms. Συνήθως, υπάρχει μία χρονική περίοδος μετά από μία αιχμή κατά την οποία ο νευρώνας δεν ανταποκρίνεται σε περαιτέρω ερεθίσματα. Η ελάχιστη αυτή χρονική διαφορά μεταξύ δύο αιχμών ενός νευρώνα αποτελεί την ανερέθιστη περίοδο κατά την οποία δεν μπορεί να παραχθεί άλλη αιχμή.

Το μέγεθος και η διάρκεια των αιχμών δεν διαφέρει αρκετά μεταξύ των διαφορετικών ειδών, διατηρώντας την ίδια μορφή καθώς οι ηλεκτρικοί παλμοί μεταδίδονται κατά μήκος του άξονα, όπως φαίνεται στο Σχήμα 2.9 (c). Συνεπώς η μορφή ενός δυναμικού δράσης μεταφέρει ελάχιστη πληροφορία, ενώ είναι η συχνότητα και ο χρονισμός των αιχμών με τα οποία επιτυγχάνεται η κωδικοποίηση των μηνυμάτων. Μία ακολουθία από δυναμικά δράσης που έχει παραχθεί από έναν νευρώνα ονομάζεται σειριακή ακολουθία αιχμών (spike train). Μπορούμε να δούμε μια ακολουθία αιχμών ως δυαδικά γεγονότα που συμβαίνουν σε διακριτό χρόνο, όπου το 1 αντιστοιχεί στην ύπαρξη μιας αιχμής και το 0 στην αντίθετη περίπτωση. Έτσι, η κωδικοποίηση της πληροφορίας μπορεί να επιτευχθεί μέσω της αλλαγής τη συχνότητας και του χρονισμού αυτών των δυαδικών γεγονότων.

Μετάδοση σημάτων

Η αιχμή, ως ηλεκτρικό σήμα, διαδίδεται σε άλλους νευρώνες μέσω της διασταύρωσης αυτών των νευρώνων, δηλαδή μία χημική σύναψη. Ο νευράξονας ενός προσυναπτικού νευρώνα πλησιάζει σε πολύ μικρή απόσταση (περίπου 20 νανόμετρα) τους δενδρίτες (ή το κυτταρικό σώμα) ενός μετασυναπτικού νευρώνα. Ο μικροσκοπικός χώρος σε μία σύναψη που συνδέει δύο νευρώνες ονομάζεται συναπτική σχισμή (cleft) και φαίνεται στο Σχήμα 2.9 (b). Σε μία τέτοια χημική σύναψη, το δυναμικό δράσης που παράγεται από τον προσυναπτικό νευρώνα πυροδοτεί την απελευθέρωση ειδικών χημικών μορίων, τους νευροδιαβιβαστές στην συναπτική σχισμή. Μόλις ο μετασυναπτικός νευρώνας ανιχνεύσει την εμφάνιση των νευροδιαβιβαστών ανοίγει ειδικά κανάλια ιόντων (ion channels) για να επιτρέψει στο ηλεκτρικό ρεύμα να εισέλθει στο εσωτερικό του. Τα κανάλια ιόντων είναι διαμεμβρανικές πρωτεΐνες που εμπλέκονται αποκλειστικά στη μεταφορά ανόργανων ιόντων από και προς τα κύτταρα. Έτσι, οι συνάψεις είναι υπεύθυνες για τον μετασχηματισμό των ηλεκτρικών σημάτων σε χημικά μόρια και μετά πάλι σε ιοντική εισροή. Το πλήθος των νευροδιαβιβαστών καθορίζει τη δύναμη της ροής του ρεύματος στον μετασυναπτικό νευρώνα [3].

Η ικανότητα αναπροσαρμογής του τρόπου επικοινωνίας των νευρώνων, ονομάζεται συναπτική πλαστικότητα (synaptic plasticity). Οι αλλαγές στην πλαστικότητα των συνάψεων συνδέεται με διάφορες μορφές μνήμης, καθώς επίσης και με την ικανότητα μάθησης. Η αποτελεσματικότητα της πλαστικότητας μιας σύναψης, όπως η δυναμική της προσυναπτικής απόκρισης λόγω της απελευθέρωσης νευροδιαβιβαστών, δεν είναι σταθερή. Υπάρχει ένα πλήθος παραγόντων που επηρεάζουν την διαδικασία της συναπτικής πλαστικότητας. Για παράδειγμα, σημαντικό ρόλο παίζει η αλλαγή της χρονικής περιόδου δραστηριότητας του υποδοχέα στον μετασυναπτικό νευρώνα [3]. Η θεωρία πίσω από την συναπτική πλαστικότητα θα αναλυθεί πιο λεπτομερώς σε επόμενη ενότητα.

2.3.2 Νευρωνική Κωδικοποίηση

Η Νευρωνική Κωδικοποίηση (NK) είναι το πεδίο που αναλύει και χαρακτηρίζει τη σχέση μεταξύ ενός ερεθίσματος με τις επιμέρους ή τις συνολικές νευρωνικές αποκρίσεις, τη σχέση μεταξύ της ηλεκτρικής δραστηριότητας των νευρώνων στο σύνολο τους, αλλά και τις διαδικασίες μετατροπής και αναπαράστασης μιας πληροφορίας σε μορφή κατάλληλη για μετάδοση και επεξεργασία [50].

Με δεδομένο ότι οι νευρώνες χαρακτηρίζονται από την ικανότητά τους να μεταδίδουν ταχέως σήματα σε μεγάλες αποστάσεις μέσω των νευρικών ινών εκμεταλλευόμενοι τους μηχανισμούς δημιουργίας ηλεκτρικών παλμών, που στην προκειμένη περίπτωση είναι τα δυναμικά ενέργειας (αιχμές), υπάρχουν πολλές περιπτώσεις που οι νευρώνες αλλάζουν την πληροφορία που δέχονται και μεταφέρουν, δηλαδή την κωδικοποιούν, είτε βάση διαφόρων χωροχρονικών προτύπων, επηρεασμένοι συνήθως από εξωγενείς παράγοντες όπως το φως, ο ήχος, η γεύση, η μυρωδιά και η αφή, είτε λόγω της φύσης του τελικού αποδέκτη, που μπορεί να είναι κάποιο αισθητήριο όργανο, όπως τα μάτια, η μύτη, η γλώσσα. Επίσης ανάλογη κωδικοποίηση υπάρχει στην περίπτωση του δυναμικού δράσης που ποικίλει σε σχέση με την διάρκεια, το πλάτος, την ένταση, αλλά και το μήκος των μεσοδιαστημάτων μεταξύ δύο διαδοχικών αιχμών σε μια σειριακή ακολουθία αιχμών [87].

Υπό το πρίσμα αυτό, η Νευρωνική Κωδικοποίηση στα ΤΝΔΑ, αποτελεί την διαδικασία κωδικοποίησης των δεδομένων εισόδου στο δίκτυο, σε κατάλληλης μορφής δεδομένα, τα οποία μεταδίδονται ως σειριακά σήματα αιχμών στο ΤΝΔΑ. Η κωδικοποίηση των πληροφοριών εισόδου ως σήματα αιχμών, καθώς και η χρονική ανάλυση των αιχμών για επεξεργασία και λήψη βέλτιστων αποφάσεων, αποτελεί το βασικότερο και δυσκολότερο αντικείμενο έρευνας και μελέτης στα ΤΝΔΑ, καθώς η προτυποποίηση των διαδικασιών και η μεθοδολογία, έγκειται στις περισσότερες των περιπτώσεων, στο τρόπο προσέγγισης του προς επίλυση προβλήματος [28].

Παρά την παραπάνω διαπίστωση, παραδοσιακά, υπάρχουν δύο βασικές θεωρίες σχετικά με της μεθόδους ΝΚ. Η μέθοδος κωδικοποίησης ρυθμού και η μέθοδος κωδικοποίησης παλμών, οι οποίες παρουσιάζονται παρακάτω.

Κωδικοποίηση Ρυθμού

Η πρώτη θεωρία υποθέτει ότι ο μέσος ρυθμός πυροδότησης των νευρώνων, φέρει όλα τα απαραίτητα στοιχεία για την μετάδοση της πληροφορίας. Ο μέσος ρυθμός πυροδότησης u είναι συνήθως κατανοητός σαν την αναλογία του μέσου αριθμού των αιχμών (spikes) n_{sp} που παρατηρούνται σε ένα συγκεκριμένο χρονικό διάστημα, όπως αυτό περιγράφεται από την παρακάτω σχέση [28]:

$$u = \frac{n_{sp}}{T} \quad (2.1)$$

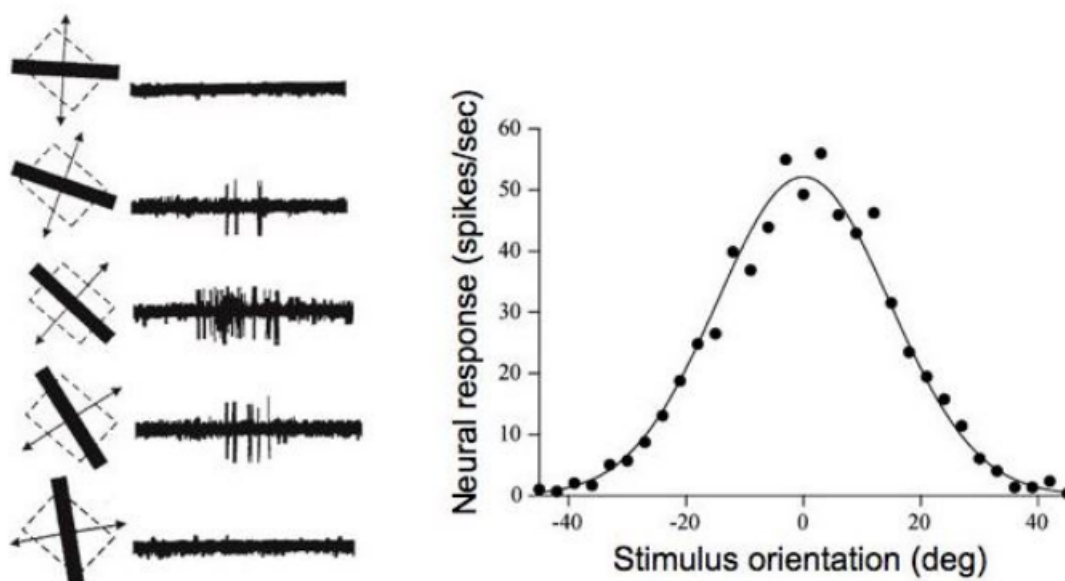
Το μοντέλο αυτό υπήρξε ιδιαίτερα επιτυχές στην χρήση του σε εφαρμογές στο πλαίσιο της προσομοίωσης των αισθήσεων ή στην χρήση μηχανοκίνητων νευρωνικών συστημάτων. Παρ' όλα αυτά, η ιδέα του μέσου ρυθμού πυροδότησης έχει επανειλημμένα επικριθεί, με κύριο επιχείρημα τη σχετικά αργή μετάδοση των πληροφοριών από τον έναν νευρώνα στον άλλον, δεδομένου ότι κάθε νευρώνας έχει να ενσωματώσει την αιχμή δραστηριότητας των προσυναπτικών νευρώνων για τουλάχιστον ένα χρονικό διάστημα. Ιδιαίτερα, για τους εξαιρετικά σύντομους χρόνους απόκρισης του εγκεφάλου σε ορισμένα ερεθίσματα, είναι αδύνατον να εξηγηθεί με την μέθοδο αυτή. Για παράδειγμα, ο ανθρώπινος εγκέφαλος μπορεί να αναγνωρίσει ένα οπτικό ερέθισμα σε περίπου 150 ms [28].

Η κωδικοποίηση ρυθμού (rate encoding) δουλεύει καλά όταν το ερέθισμα αλλάζει αργά και η χρονική διάρκεια παρατήρησης είναι αρκετά μεγάλη ώστε να προλάβει να εκτιμηθεί ο ρυθμός παραγωγής των αιχμών. Ωστόσο, στην πράξη ένα ερέθισμα, όπως μία οπτική αισθητηριακή είσοδος, αλλάζει με γρήγορο ρυθμό, ενώ οι νευρώνες απαντούν σε ένα πολύ σύντομο χρονικό διάστημα. Δεδομένου ότι η χρονική κωδικοποίηση κωδικοποιεί την πληροφορία στον ακριβή χρονισμό των αιχμών, προτιμάται για την κωδικοποίηση ερεθισμάτων που αλλάζουν γρήγορα.

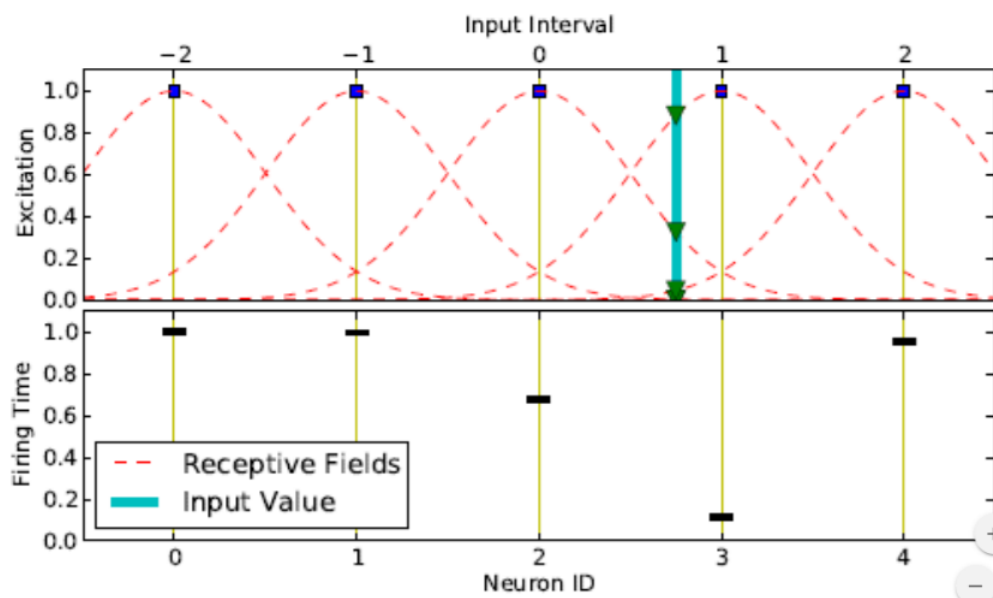
Είναι γνωστό ότι ένας μέτριος αριθμός νευρωνικών επιπέδων εμπλέκονται στην επεξεργασία των οπτικών ερεθισμάτων. Εάν κάθε επίπεδο έπρεπε να περιμένει μια περίοδο για να λάβει την πληροφορία από το προηγούμενο επίπεδο, ο χρόνος αναγνώρισης θα ήταν πολύ μεγαλύτερος από τον προαναφερθέν. Ωστόσο, υπάρχει και μια άλλη εκδοχή για την έννοια του μέσου ρυθμού πυροδότησης, η οποία ορίζεται ως η μέση δραστηριότητα αιχμών πάνω από ένα πληθυσμό νευρώνων. Συγκεκριμένα ένας μετασυναπτικός νευρώνας λαμβάνει εισόδους υπό μορφή αιχμών που εκπέμπονται από έναν πληθυσμό προσυναπτικών νευρώνων. Ο πληθυσμός αυτός παράγει μια ορισμένη δραστηριότητα αιχμών η οποία ορίζεται ως το κλάσμα των ενεργών νευρώνων μέσα σε κάποιο σύντομο χρονικό διάστημα $[t, t + \Delta t]$, όπως αυτό παρουσιάζεται στην παρακάτω σχέση [28]:

$$A = \frac{1}{\Delta t} \frac{n_{act}(t, t + \Delta t)}{N} \quad (2.2)$$

, όπου $n_{act}(t, t + \Delta t)$ ο αριθμός νευρώνων στο διάστημα $[t, t + \Delta t]$ και N ο συνολικός αριθμός του πληθυσμού των νευρώνων. Θα πρέπει να σημειωθεί ότι στην περίπτωση αυτή η δραστηριότητα του πληθυσμού των νευρώνων μπορεί να μεταβάλλεται γρήγορα και έτσι επιτρέπουν την ταχεία ανταπόκριση στα μεταβαλλόμενα ερεθίσματα, βελτιστοποιώντας την γενικότερη μέθοδο [28].



Σχήμα 2.10: Παράδειγμα κωδικοποίησης ρυθμού νευρωνικών σημάτων. Αριστερά φαίνονται οι ακολουθίες αιχμών για διαφορετικούς προσανατολισμούς του ερεθίσματος ενός V1 κυττάρου μιας γάτας. Το τετράγωνο αναπαριστά το οπτικό υποδεκτικό πεδίο (receptive field) του νευρώνα, ενώ η μαύρη μπάρα τοποθετείται σε διαφορετικούς προσανατολισμούς. Δεξιά βλέπουμε την καμπύλη συντονισμού (tuning curve), ρυθμός παραγωγής αιχμών (σε αιχμές ανά δευτερόλεπτο) σε συνάρτηση με τον προσανατολισμό του ερεθίσματος (σε μοίρες), του νευρώνα [5]. Καθώς το ερέθισμα προσανατολίζεται στις 0 μοίρες ο ρυθμός παραγωγής αιχμών αυξάνεται.



Σχήμα 2.11: Κωδικοποίηση Πληθυσμού με Γκαουσιανά Δεκτικά Πεδία [49].

Κωδικοποίηση Παλμού

Η δεύτερη θεωρία αφορά την μέθοδο κωδικοποίησης των παλμών (pulse encoding). Σε αυτή την προσέγγιση, λαμβάνεται ο ακριβής χρόνος μετάδοσης των αιχμών, το άθροισμα των οποίων μεταφράζεται ως παλμός, ο φορέας πληροφοριών μεταξύ των νευρώνων. Πειραματικές αποδείξεις για χρονικές συσχετίσεις μεταξύ αιχμών δόθηκαν μέσω προσομοιώσεων σε υπολογιστή και απέδειξαν την εγκυρότητα της μεθόδου, ιδιαίτερα σε εφαρμογές δυναμικών συστημάτων που εξαρτώνται από τον χρόνο [28].

Μία μέθοδος κωδικοποίησης παλμού που βασίζεται στον χρονισμό της πρώτης αιχμής αμέσως μετά από ένα σήμα αναφοράς, ονομάζεται χρόνος της πρώτης αιχμής (time to first spike) και είναι εμπνευσμένη από την οπτική επεξεργασία του ανθρώπινου οφθαλμού. Σύμφωνα με την μέθοδο αυτή οι πληροφορίες κωδικοποιούνται στον χρόνο που μεσολαβεί μεταξύ του χρόνου έναρξης του ερεθισμού και τον χρόνο απόκρισης της πρώτης αιχμής. Η κωδικοποίηση μπορεί να εφαρμοστεί με χρήση ενός μόνο νευρώνα με ανασταλτικό δυναμικό (inhibitory) και ανάδραση (feedback), που εμποδίζει την εκπομπή άλλων αιχμών [28].

Η κωδικοποίηση παλμού βασίζεται στο επιχείρημα ότι κάθε νευρώνας έχει το χρόνο να εκπέμψει μόνο λίγες αιχμές που μπορούν να συμβάλουν στη συνολική επεξεργασία ενός ερεθίσματος. Με δεδομένο ότι ένα νέο ερέθισμα υφίσταται επεξεργασία στα πρώτα 20 έως 50 *ms* μετά την έναρξη του, οι πρότερες αιχμές μεταφέρουν τις περισσότερες και συνήθως σημαντικότερες πληροφορίες σχετικά με το ερέθισμα [28]. Χαρακτηριστικό παράδειγμα προσομοίωσης νευρώνων με την κωδικοποίηση αυτή, αποτελεί η κωδικοποίηση πληροφοριών για προσομοίωση συστημάτων αφής, στα οποία πρώτα μεταφέρονται οι πληροφορίες από τα δάχτυλα. Αποτελεί ενδεικτική λύση σε περιπτώσεις άμεσης επεξεργασίας πληροφοριών [45].

Επίσης σημαντικές μπορούν να θεωρηθούν οι διαδικασίες συσχέτισης και συγχρονισμού μεταξύ παλμών, οι οποίες μπορούν να δημιουργήσουν προϋποθέσεις για δυναμική κωδικοποίηση μιας πληροφορίας. Γενικότερα όμως, κάθε χωροχρονικό πρότυπο παλμών θα μπορούσε να είναι δυνητικά μέθοδος κωδικοποίησης μιας συγκεκριμένης πληροφορίας, ακόμα και για τις αιχμές που έχουν κάποια σχετική χρονική καθυστέρηση, οι οποίες δυνητικά μπορεί να κωδικοποιούν ένα συγκεκριμένο ερέθισμα [28, 45].

Κωδικοποίηση Πληθυσμού

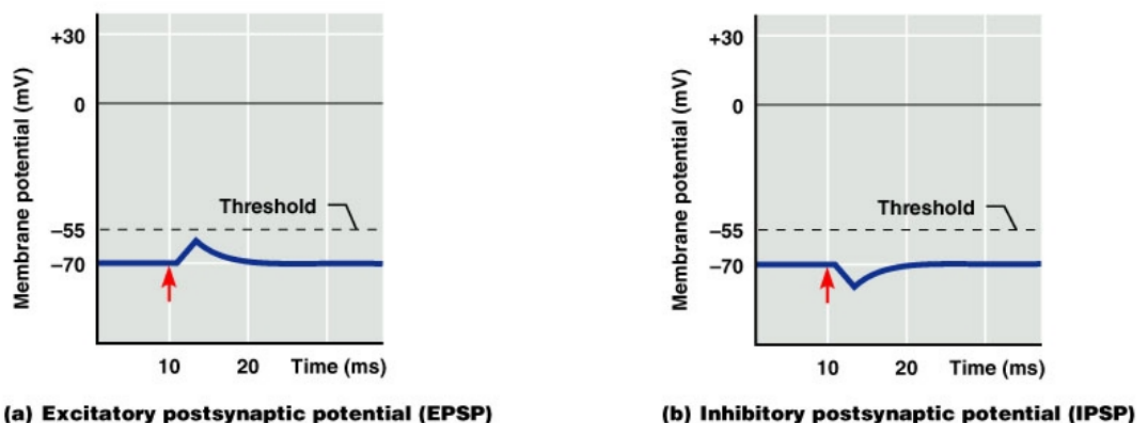
Η Κωδικοποίηση Κατάταξης Πληθυσμού (Population encoding) είναι μια τεχνική κωδικοποίησης η οποία επιτρέπει την αντιστοίχιση των πραγματικών τιμών ενός συνόλου δεδομένων, σε μια ακολουθία από αιχμές με βάση ένα σύνολο από δεκτικά πεδία (receptive fields). Τα δεκτικά πεδία, τα οποία για την συγκεκριμένη περίπτωση επιλέχθηκαν να είναι Γκαουσιανά (Gaussian), επιτρέπουν την κωδικοποίηση συνεχών τιμών χρησιμοποιώντας ένα σύνολο νευρώνων με επικαλυπτόμενα προφίλ ευαισθησίας. Κάθε μεταβλητή εισόδου κωδικοποιείται ανεξάρτητα από ένα σύνολο από M μονοδιάστατα δεκτικά πεδία [49]. Συγκεκριμένα, για μια μεταβλητή n ορίζεται το διάστημα $[I_{min}^n, I_{max}^n]$. Ένα Γκαουσιανό δεκτικό πεδίο για το νευρώνα i ορίζεται από το κέντρο του μ_i όπως αυτό δίνεται από τον παρακάτω τύπο[49]:

$$\mu_i = I_{min}^n + \frac{2i - 3}{2} \frac{I_{max}^n - I_{min}^n}{M - 2} \quad (2.3)$$

και από το πλάτος του σ [49]:

$$\sigma = \frac{1}{\beta} \frac{I_{max}^n - I_{min}^n}{M - 2} \quad (2.4)$$

, όπου β , $1 \leq \beta \leq 2$ η παράμετρος που καθορίζει το πλάτος του κάθε Γκαουσιανού δεκτικού πεδίου.



Σχήμα 2.12: Γραφικές παραστάσεις διεγερτικού και ανασταλτικού μετασυναπτικού δυναμικού που έχει προκληθεί από την διάδοση μιας αιχμής. Το κόκκινο βέλος υποδεικνύει τη χρονική στιγμή που η αιχμή έφτασε στον νευρώνα [64].

2.3.3 Μοντελοποίηση νευρώνων


Δυναμική νευρώνων

Το αποτέλεσμα της εισροής ιόντων στον μετασυναπτικό νευρώνα που προκαλείται από την διάδοση μιας αιχμής είναι μία αλλαγή στη διαφορά δυναμικού μεταξύ του εσωτερικού και του εξωτερικού του κυτταρικού σώματος. Αυτή η διαφορά δυναμικού ονομάζεται δυναμικό μεμβράνης (membrane potential). Όταν ένας μετασυναπτικός νευρώνας δεν δέχεται κάποιο ερέθισμα το δυναμικό μεμβράνης του μένει σταθερό στο δυναμικό ηρεμίας (resting potential). Μόλις καταφτάσει μία αιχμή, το δυναμικό μεμβράνης αποπολώνεται (αύξηση δυναμικού) είτε επαναπολώνεται (μείωση δυναμικού) ανάλογα με το είδος τη σύναψης. Αμέσως μετά, επιστρέφει στο δυναμικό ηρεμίας λόγω διαρροής από τη μεμβράνη μέσω των καναλιών διαρροής (leak channels). Η μεταβολή που προκαλεί ένα δυναμικό δράσης ονομάζεται μετασυναπτικό δυναμικό (Post-Synaptic Potential - PSP) και το ποσοστό της ηλεκτρικής δραστηριότητας που μεταδίδεται, συναπτικό βάρος (synaptic weight).

Μια συναπτική διαβίβαση, ανάλογα με τον τύπο του νευροδιαβιβαστή που εκκρίνεται, μπορεί να είναι είτε διεγερτική καθώς προκαλεί αποπόλωση της μεμβράνης του μετασυναπτικού νευρώνα και ονομάζεται διεγερτικό μετασυναπτικό δυναμικό (Excitatory Post-Synaptic Potential - EPSP) (βλέπε Σχήμα 2.12 (a)), είτε ανασταλτική καθώς προκαλεί επαναπόλωση της μεμβράνης του μετασυναπτικού νευρώνα και ονομάζεται ανασταλτικό μετασυναπτικό δυναμικό (Inhibitory Post-Synaptic Potential - IPSP) (βλέπε Σχήμα 2.12 (b)). Αιχμές που καταφθάνουν σε διαφορετικές συνάψεις του ίδιου μετασυναπτικού νευρώνα έχουν μετασυναπτικά δυναμικά με διαφορετικά πλάτη ανάλογα με την αποτελεσματικότητα της δεδομένης σύναψης [3].

Είναι άξιο αναφοράς το γεγονός ότι πολλαπλά μετασυναπτικά δυναμικά έχουν ένα συσσωρευτικό αποτέλεσμα στο δυναμικό της μεμβράνης τόσο χωρικά όσο και χρονικά. Η συσσώρευση αποτελεί ουσιαστικά μία απλή άθροιση των μετασυναπτικών δυναμικών μέχρις ότου το δυναμικό της μεμβράνης να φτάσει ένα δεδομένο κατώφλι (threshold). Τότε είναι που παράγεται ένα δυναμικό δράσης στον μετασυναπτικό νευρώνα. Στο Σχήμα 2.13 απεικονίζεται οι χρονικές και χωρικές αθροίσεις των μετασυναπτικών δυναμικών κάτω από διαφορετικές συνθήκες. Η χρονική άθροιση αναφέρεται στο συσσωρευτικό αποτέλεσμα μιας μεμονωμένης σύναψης, ενώ η χωρική άθροιση συνδυάζει τα μετασυναπτικά δυναμικά που προκαλούνται από πολλαπλές συνάψεις [12].

Το δυναμικό της μεμβράνης, τα μετασυναπτικά δυναμικά, καθώς και οι ακολουθίες αιχμών




Σχήμα 2.13: Οπτική αναπαράσταση άθροισης μετασυναπτικών δυναμικών. (a) Μεμονωμένα διεγερτικά μετασυναπτικά δυναμικά συνήθως δεν επαρκούν ώστε να προκληθεί ένα δυναμικό δράσης χωρίς άθροιση πολλών μαζί. (b) Η χρονική άθροιση δύο διεγερτικών δυναμικών της ίδιας σύναψης μπορεί να παράξει ένα δυναμικό δράσης. (c) Η χωρική άθροιση δύο διεγερτικών δυναμικών δύο διαφορετικών συνάψεων μπορεί επίσης να προκαλέσει ένα δυναμικό δράσης. (d) Η άθροιση ενός ανασταλτικού δυναμικού και ενός διεγερτικού δεν μπορεί να παράξει αιχμή [12].

εξαρτώνται από τον χρόνο, ενώ οι νευρώνες που συναντώνται στα Τεχνητά Νευρωνικά Δίκτυα - ΤΝΔ (Artificial Neural Networks), όπως οι σιγμοειδείς μονάδες, χρησιμοποιούν μόνο αριθμητικές τιμές, χωρίς να περιέχουν κάποια χρονική πληροφορία. Ένας συνηθισμένος τεχνητός νευρώνας (Σχήμα 2.14 (a)) αθροίζει δεδομένα εισόδου $\sum x_i w_i$ με βάρη και εφαρμόζει μία συνάρτηση ενεργοποίησης f στο άθροισμα που προκύπτει. Συνήθως, συμπεριλαμβάνεται και μία πόλωση (bias) στην σταθμισμένη άθροιση. Παράλληλα, οι εισοδοί ενός νευρώνα που παράγει αιχμές (Σχήμα 2.14 (b)) είναι ακολουθίες αιχμών οι οποίες παράγονται από προσυναπτικούς νευρώνες. Ως αποτέλεσμα δημιουργούνται μετασυναπτικά δυναμικά στον μετασυναπτικό νευρώνα, ο οποίος παράγει με τη σειρά του μία ακολουθία αιχμών. Αυτές οι θεμελιώδεις διαφορές στις αναπαραστάσεις εισόδου και εξόδου, καθώς και στους υπολογισμούς που εκτελεί κάθε νευρώνας, οδήγησαν στην δημιουργία διαφόρων μοντέλων που περιγράφουν την δυναμική ενός νευρώνα, τα οποία θα δούμε στην επόμενη υποενότητα [61].

Μοντέλα νευρώνων

Σε αυτή την υποενότητα θα αναλύσουμε μερικά από τα πιο γνωστά μαθηματικά μοντέλα που περιγράφουν την δυναμική των νευρώνων. Όπως θα δούμε, για την μοντελοποίηση ενός νευρώνα αιχμών είναι απαραίτητη η μαθηματική περιγραφή της εξέλιξης του δυναμικού της μεμβράνης και ενός μηχανισμού παραγωγής αιχμών.

- **Μοντέλο Leaky Integrate-and-Fire (LIF):** Η εξέλιξη του δυναμικού της μεμβράνης V μπορεί να μοντελοποιηθεί με τη χρήση ενός κυκλώματος RC (αντιστάτης-πυκνωτής) το οποίο αποτελείται από την χωρητικότητα μεμβράνης C_m και την αντίσταση μεμβράνης R_m . Και οι δύο μεταβλητές εξαρτώνται από την ροή ρεύματος εισόδου I (βλέπε Σχήμα 2.15). Στην κατάσταση ηρεμίας δεν υπάρχει κάποια είσοδος και το δυναμικό μεμβράνης V παραμένει σε σταθερή τιμή V_{rest} . Όταν ο νευρώνας διαρρέεται από ρεύμα, ο πυκνωτής θα φορτιστεί με ρεύμα $I_C(t)$ και η αντίσταση θα διαπεραστεί από ρεύμα $I_R(t)$ (Εξίσωση 2.5). Όταν το ρεύμα εισόδου σταματήσει, το δυναμικό μεμβράνης θα επανέλθει στην τιμή ηρεμίας, αφού



Σχήμα 2.14: Σύγκριση μεταξύ του μηχανισμού επεξεργασίας ενός τεχνητού νευρώνα και ενός νευρώνα αιχμών. (a) Ένας τεχνητός νευρώνας λαμβάνει αριθμητικές τιμές ενός διανύσματος x ως είσοδο, εφαρμόζει σταθμισμένη άθροιση σε αυτές και τέλος μία συνάρτηση ενεργοποίησης f . (b) Ακολουθίες αιχμών εισέρχονται στον νευρώνα ως ερεθίσματα εισόδου, πυροδοτούν μετασυναπτικά δυναμικά που αθροίζονται γραμμικά, μέσω συνάψεων διαφορετικής συναπτικής απόδοσης w , και ο μετασυναπτικός νευρώνας παράγει ως έξοδο αιχμές, όταν το δυναμικό μεμβράνης φτάνει σε ένα δεδομένο κατώφλι [61].

υπάρχει ρεύμα που θα διαρρέει από την αντίσταση [28].

$$\begin{aligned} I(t) &= I_R(t) + I_C(t) \\ &= \frac{V - V_{rest}}{R_m} + C_m \frac{dV}{dt} \end{aligned} \quad (2.5)$$

Η συνηθισμένη μορφή του μοντέλου LIF περιγράφει την εξέλιξη του δυναμικού της μεμβράνης (όταν αυτό βρίσκεται κάτω από το κατώφλι), όπως φαίνεται από την Εξίσωση 2.6.


$$\tau_m \frac{dV}{dt} = -(V - V_{rest}) + R_m I(t) \quad (2.6)$$

, όπου $\tau_m = C_m R_m$ η σταθερά χρόνου της μεμβράνης. Μόλις το δυναμικό μεμβράνης φτάσει την τιμή κατωφλίου V_{thresh} , λαμβάνει μία τιμή επανεκκίνησης (reset) V_{reset} , η οποία συνήθως είναι μικρότερη του V_{rest} .

Συνοψίζοντας, το μοντέλο LIF χρησιμοποιεί την γραμμική διαφορική Εξίσωση 2.6 για την περιγραφή της εξέλιξης του δυναμικού της μεμβράνης και μια τιμή κατωφλίου για την παραγωγή αιχμής.

- **Μοντέλο Hodgkin-Huxley:** Το βραβευμένο με Νόμπελ μοντέλο των Hodgkin και Huxley [41] εξηγεί του ιοντικούς μηχανισμούς που παράγουν και διαδίδουν δυναμικά δράσης στον νευράξονα του καλαμαριού. Το ρεύμα $I_R(t)$, το οποίο ρέει μέσα από την αντίσταση της μεμβράνης καθορίζεται από τρία κανάλια ιόντων: ένα κανάλι διαρροής με αγωγιμότητα g_L , το κανάλι νατρίου με αγωγιμότητα g_{Na} και το κανάλι καλίου με αγωγιμότητα g_K . Τα ρεύματα που ρέουν μέσα από αυτά τα κανάλια είναι ανάλογα της διαφοράς του δυναμικού μεμβράνης και του δυναμικού αντιστροφής (reversal potential) του κάθε καναλιού: $V - E_L$, $V - E_{Na}$ και $V - E_K$ αντίστοιχα. Συνεπώς η εξίσωση 2.5 περιγράφεται ως εξής:

$$\begin{aligned} I(t) &= I_L(t) + I_{Na}(t) + I_K(t) + I_C(t) \\ &= g_L(V - E_L) + g_{Na}m^3h(V - E_{Na}) + g_Kn^4(V - E_K) + C_m \frac{dV}{dt} \end{aligned} \quad (2.7)$$



Σχήμα 2.15: Μοντελοποίηση κυτταρικής μεμβράνης. Η κυτταρική μεμβράνη συμπεριφέρεται σαν ένα κύκλωμα Αντιστάτη-Πυκνωτή. Το ρεύμα εισόδου $I(t)$ εισέρχεται στον νευρώνα, φορτίζοντας τον πυκνωτή C , ενώ διαρρέει από την αντίσταση R . Η αντίσταση βρίσκεται σε σειρά με την μπαταρία V_{rest} που αντιστοιχεί στο δυναμικό ηρεμίας [28].

Μπορούμε να δούμε το μοντέλο Hodgkin-Huxley ως μία μη γραμμική διαφορική εξίσωση με τέσσερις μεταβλητές: V , m , h και n , οι οποίες μεταβάλλονται με τον χρόνο.

$$\begin{aligned}
 C_m \frac{dV}{dt} &= I(t) - g_K n^4 (V - E_K) - g_{Na} m^3 h (V - E_{Na}) - g_L (V - E_L) & (2.8) \\
 \frac{dm}{dt} &= \alpha_m(V)(1 - m) - \beta_m(V)m \\
 \frac{dn}{dt} &= \alpha_n(V)(1 - n) - \beta_n(V)n \\
 \frac{dh}{dt} &= \alpha_h(V)(1 - h) - \beta_h(V)h
 \end{aligned}$$

, όπου $\alpha(V)$ και $\beta(V)$ συναρτήσεις του δυναμικού της μεμβράνης.

Σχετικά με τον μηχανισμό έναρξης μιας αιχμής, η πιο σημαντική ιδιότητα του μοντέλου είναι το πως μπορεί να παράγει δυναμικά δράσης μέσω αλλαγών στις παραπάνω δυναμικές εσωτερικές μεταβλητές και μόνο.

Οι εξισώσεις Hodgkin-Huxley παρέχουν ένα λεπτομερές, ποσοτικό και αρκετά ακριβές μαθηματικό μοντέλο το οποίο εξηγεί την εξέλιξη του δυναμικού της μεμβράνης και των δυναμικών δράσης [11]. Ωστόσο, η αριθμητική του πολυπλοκότητα και τα υψηλά μη γραμμικά του χαρακτηριστικά, του απαγορεύουν από το να μπορεί να κατανοηθεί διαισθητικά, ενώ κάνει τις προσομοιώσεις μεγάλης κλίμακας υπολογιστικά δαπανηρές. Συνεπώς, η επιλογή ενός μοντέλου δυναμικής των νευρώνων θα πρέπει να λαμβάνει υπόψη τους στόχους μιας έρευνας, τον βαθμό ακρίβειας που αυτή απαιτεί καθώς και την διαθέσιμη υπολογιστική ισχύ.

- **Μοντέλο Izhikevich:** Το μοντέλο Izhikevich προτάθηκε με στόχο να λύσει τα προβλήματα στην υπολογιστική πολυπλοκότητα του μοντέλου Hodgkin-Huxley και την μη επαρκή ικανότητα του μοντέλου LIF στην αναπαραγωγή της σύνθετης δυναμικής των φλοιωδών νευρώνων [45]. Έτσι, το μοντέλο του Izhikevich μπορεί να χρησιμοποιηθεί για την προσομοίωση εγκεφαλικών μοντέλων μεγάλης κλίμακας που αποτελούνται από βιολογικούς νευρώνες.

Το δυναμικό της μεμβράνης εξελίσσεται με βάση ενός ζεύγους εξισώσεων:

$$\begin{aligned}\frac{dV}{dt} &= 0.04V^2 + 5V + 140 - u - I(t) \\ \frac{du}{dt} &= \alpha(bV - u)\end{aligned}\quad (2.9)$$

, όπου V είναι το δυναμικό της μεμβράνης και το u αναπαριστά την επαναφορά της μεμβράνης.

Σχετικά με την παραγωγή αιχμών, η έναρξη της ενεργοποίησης ενός δυναμικού δράσης παράγεται από την Εξίσωση 2.10. Ωστόσο, χρειάζεται και μία μέθοδος επαναφοράς:

$$\begin{aligned}V &= c \\ u &= u + d, \text{ όταν } V \geq 30\end{aligned}\quad (2.10)$$

Οι παράμετροι a , b , c και d είναι σταθερές και μπορούν να διαμορφωθούν κατάλληλα για να αναπαράγουν διάφορες δυναμικές πραγματικών βιολογικών νευρώνων [46].

Μοντέλα συνάψεων

Για την εφαρμογή των νευρωνικών μοντέλων στην συναπτική διάδοση αιχμών, μπορούμε να χρησιμοποιήσουμε δύο είδη συνάψεων: τις συνάψεις που βασίζονται στο ρεύμα (current-based synapses) και αυτές που βασίζονται στην αγωγιμότητα (conductance-based synapses). Έτσι, η συναπτική απόδοση w καθορίζει είτε την ένταση του ρεύματος εισόδου που διαρρέει την σύναψη:

$$I(t) = w(t) \quad (2.11)$$

είτε την ηλεκτρική αγωγιμότητα g_{syn} του καναλιού ιόντων:

$$I(t) = g_{syn}(V - E_{syn}) = w(t)(V - E_{syn}) \quad (2.12)$$

, όπου το E_{syn} αναπαριστά το δυναμικό επαναφοράς της σύναψης. Αθροίζοντας όλα τα συναπτικά ρεύματα που καταλήγουν στον ίδιο μετασυναπτικό νευρώνα, ουσιαστικά αναπαριστούμε το εξωτερικό ρεύμα $I(t)$ για όλα τα νευρωνικά μοντέλα που αναφέρθηκαν στην προηγούμενη ενότητα, δεδομένου ότι και οι δύο εξισώσεις περιγράφουν την ένταση του συναπτικού ρεύματος.

Η ροή του ρεύματος έχει συνήθως μία πολύ μεγαλύτερη σταθερά χρόνου καθώς φθίνει με το χρόνο σε σύγκριση με ένα δυναμικό δράσης. Έτσι, μία απλή εκθετική μείωση είναι αρκετή για να μοντελοποιήσει την φθίνουσα απόδοση μιας σύναψης. Υποθέτοντας ότι έχουμε εμφάνιση αιχμών στους χρόνους $t = t_0, t_1, \dots, t_n$, το αρχικό βάρος της σύναψης είναι w_0 και η συναπτική σταθερά χρόνου περιγράφεται από τη μεταβλητή τ_{syn} , το φθίνων συναπτικό ρεύμα (ή αγωγιμότητα) μπορεί να περιγραφεί από την ακόλουθη μαθηματική σχέση:

$$w(t) = \sum_k w_0 e^{-(t-t_k)/\tau_{syn}} \quad (2.13)$$

2.3.4 Συναπτική πλαστικότητα και μάθηση

Διαδικασία Μάθησης


Το κύριο χαρακτηριστικό γενικότερα των νευρωνικών δικτύων, είναι η εγγενής ικανότητα μάθησης. Ως μάθηση μπορεί να οριστεί η σταδιακή βελτίωση της ικανότητας του δικτύου να επιλύει κάποιο πρόβλημα. Η μάθηση επιτυγχάνεται μέσω της εκπαίδευσης, η οποία μπορεί να θεωρηθεί μία επαναληπτική διαδικασία σταδιακής προσαρμογής των παραμέτρων του δικτύου, συνήθως των βαρών και της πόλωσής του, σε τιμές κατάλληλες ώστε να επιλύεται με επαρκή επιτυχία το προς εξέταση πρόβλημα. Αφού ένα δίκτυο εκπαιδευτεί, οι παράμετροί του συνήθως σταθεροποιούνται στις κατάλληλες τιμές και από εκεί κι έπειτα βρίσκεται στην βέλτιστη κατάσταση για να επιλύσει το εν λόγω πρόβλημα. Το ζητούμενο είναι το δίκτυο να χαρακτηρίζεται από μία ικανότητα γενίκευσης, να μπορεί δηλαδή να δίνει ορθές εξόδους για εισόδους καινοφανείς και διαφορετικές από αυτές με τις οποίες εκπαιδεύτηκε [50].

Η δυναμική που παρουσιάζει ένα Νευρωνικό Δίκτυο Αιχμών ορίζεται από την συνδετικότητα του και από την δύναμη των συναπτικών του συνδέσεων. Η μάθηση σε ένα τέτοιο δίκτυο συνεπάγεται την προσαρμογή των συνάψεων του μέσω επαναλαμβανόμενων βελτιστοποιήσεων. Η επιλογή του κατάλληλου αλγορίθμου μάθησης για ένα πρόβλημα εξαρτάται από τρία θεμελιώδη χαρακτηριστικά του χρησιμοποιούμενου μοντέλου. Πρώτον, ορισμένοι αλγόριθμοι μπορούν να εφαρμοστούν μόνο σε συγκεκριμένες τοπολογίες δικτύων και νευρωνικά μοντέλα. Έτσι, το μοντέλο που θα επιλεγεί θα περιορίσει σημαντικά την επιλογή του αλγορίθμου μάθησης. Κατα δεύτερον, ένα επιπλέον ζήτημα που εγείρεται είναι το αν η εκπαίδευση ή η μάθηση ενός συστήματος θα πρέπει να υλοποιηθεί πάνω στο υλικό ή να γίνει η μεταφορά του ήδη εκπαιδευμένου δικτύου στο νευρομορφικό υλικό. Μία τρίτη απόφαση που πρέπει να παρθεί, είναι το αν το δίκτυο πρόκειται να εκπαιδευτεί με ή χωρίς επίβλεψη.

Μια ποικιλία από σοβαρά προβλήματα επηρεάζουν σημαντικά τις διαδικασίες μάθησης στα ΝΔΑ, καθώς οι ρητές απαιτήσεις εξάρτησης των αποτελεσμάτων σε σχέση με μια προκαθορισμένη είσοδο, η διάταξη του λειτουργίας με βάση ακριβείς χωροχρονικές παραμέτρους, η ασύγχρονη επεξεργασία των πληροφοριών που απαιτεί συνήθως εξειδικευμένο λογισμικό ή και υλικό, καθώς και οι πρόσθετες δυσκολίες που εισάγουν οι πολύπλοκες αρχιτεκτονικές και τοπολογίες που χρησιμοποιούνται από τα δίκτυα αυτά, δεν επιτρέπουν συνήθως την εφαρμογή μιας απλής μεθόδου μάθησης, όπως η οπισθοδιάδοση [28]. Οι σημαντικότερες τεχνικές μάθησης που έχουν προταθεί και έχουν κατά καιρούς δοκιμαστεί σε εφαρμογές ΤΝΔΑ, παρουσιάζονται στη συνέχεια.

Πλαστικότητα εξαρτώμενη από τον χρονισμό των αιχμών

Όπως αναφέραμε στην ενότητα 2.3.1, η συναπτική πλαστικότητα επιτρέπει την ύπαρξη διαφόρων λειτουργιών μνήμης και μάθησης σε νευρωνικό επίπεδο στον εγκέφαλο. Βιολογικές παρατηρήσεις έχουν προσφέρει αποδείξεις ότι η μεταβολή της συναπτικής απόδοσης σχετίζεται άμεσα με τον χρονισμό των προσυναπτικών και μετασυναπτικών αιχμών στους νευρώνες [7]. Αυτή η λειτουργική αλληλεπίδραση μεταξύ της χρονικά συνδυασμένης ενεργοποίησης διαφορετικών συναπτικών οδών στον νευρώνα συνιστά ουσιαστικά ένα είδος συνειρμού στο μοριακοκυτταρικό επίπεδο. Ο συνειρμός αυτός υφίσταται από το γεγονός ότι σε όλες αυτές τις περιπτώσεις συμβαίνει σύγχρονη, χρονικά συνδυασμένη, προσυναπτική και μετασυναπτική ενεργοποίηση. Ο ρόλος αυτής της συνειρμικής διεργασίας εκφράζεται πολύ χαρακτηριστικά μέσω της πειραματικής συνθήκης, κατά την οποία ενεργοποιούνται σύγχρονα ο προσυναπτικός και μετασυναπτικός νευρώνας. Η συναπτική πλαστικότητα που επάγεται μέσω αυτής της συνθήκης καλείται πλαστικότητα εξαρτώμενη από τον χρονισμό των αιχμών (Spike-Timing Dependent Plasticity - STDP), με τον βασικό της μηχανισμό να οπτικοποιείται στο Σχήμα 2.16 [95]. Για το ΝΔΑ που θα χρησιμοποιήσουμε σε αυτή την εργασία, θα υλοποιήσουμε μία παραλλαγή του κανόνα STDP, ο οποίος αποτελεί μία από



Σχήμα 2.16: Παρουσίαση του μηχανισμού μάθησης STDP [95]. Οι μικροί κύκλοι καταγράφουν την μεταβολή του συναπτικού βάρους σε πραγματικές βιολογικές παρατηρήσεις 60 ζευγών νευρώνων του υπόκαμπου. Όπως βλέπουμε στην γραφική παράσταση, οι καμπύλες που αναπαριστούν την εκθετική μείωση του βάρους σε συνάρτηση με τον σχετικό χρονισμό των προσυναπτικών και μετασυναπτικών αιχμών, ταιριάζουν αρκετά καλά στα πραγματικά βιολογικά δεδομένα.

τις πιο πολλά υποσχόμενες και εκτενώς μελετημένες μορφές μάθησης νευρωνικών δικτύων χωρίς επίβλεψη.

Η βασική εξίσωση που περιγράφει την μεταβολή του συναπτικού βάρους στο πρότυπο μοντέλο STDP [95] είναι η ακόλουθη:

$$\Delta w = \begin{cases} A_+ e^{-\Delta t/\tau_+}, & \text{όταν } \Delta t \geq 0 \\ -A_- e^{\Delta t/\tau_-}, & \text{όταν } \Delta t < 0 \end{cases} \quad (2.14)$$

Το συναπτικό δυναμικό αυξάνεται όταν μία μετασυναπτική αιχμή εμφανίζεται μετά από μία προσυναπτική αιχμή τόσο όσο ορίζει η εκθετική καμπύλη με σταθερά χρόνου τ_+ και αρχική τιμή A_+ . Ωστόσο, όταν μία μετασυναπτική αιχμή παράγεται πριν από μία προσυναπτική, έχουμε μείωση του βάρους σύμφωνα με βάση την εκθετική καμπύλη που ορίζεται από τις σταθερές τ_- και A_- . Το Δt ορίζει τη διαφορά μεταξύ του χρόνου άφιξης μιας προσυναπτικής αιχμής και του χρόνου εμφάνισης ενός δυναμικού δράσης που εκπέμπεται από το νευρώνα. Εκτός από το πρότυπο μοντέλο STDP που περιγράφεται από την Εξίσωση 2.14, έχουν προταθεί παραλλαγές του κανόνα μάθησης STDP με στόχο την επίτευξη διαφορετικών ταχυτήτων μάθησης και ακρίβειας ταξινόμησης.

Μάθηση Ενός Περάσματος

Ο Αλγόριθμος Μάθησης Ενός Περάσματος ((One-pass learning) αποτελεί μια εξαιρετικά εύκολη και απλοποιημένη διαδικασία κατηγοριοποίησης, η οποία ολοκληρώνεται σε πολύ γρήγορο χρονικό διάστημα καθώς δεν απαιτεί ιδιαίτερους υπολογιστικούς πόρους και ενδείκνυται για γραμμικά προβλήματα ή ανάλυση δεδομένων που μπορεί να προέρχονται από μια κατανομή [49].

Σε γενικές γραμμές η λειτουργία του αλγορίθμου περιγράφεται ως εξής:

- Πραγματοποιείται μια σειριακή εισαγωγή των δεδομένων-αντικειμένων στο σύστημα.
- Το πρώτο αντικείμενο γίνεται ο εκπρόσωπος της πρώτης κατηγορίας.

- Κάθε επόμενο αντικείμενο συγκρίνεται με όλους τους εκπροσώπους των υφιστάμενων κατηγοριών κατά το χρόνο επεξεργασίας του και κατατάσσεται σε κάποια κατηγορία με βάση κάποια κριτήρια.
- Όταν ένα αντικείμενο έχει εκχωρηθεί σε μια κατηγορία ο εκπρόσωπος για την εν λόγω κατηγορία επανυπολογίζεται.
- Αν ένα νέο αντικείμενο αποτύχει να καταταχθεί σε μια από τις ήδη υπάρχουσες κατηγορίες, γίνεται εκπρόσωπος μιας νέας κατηγορίας [49].

2.3.5 Προσομοίωση Νευρωνικών Δικτύων Αιχμών

Στην Ενότητα 2.3.3, περιγράψαμε τη δυναμική των νευρώνων, δηλαδή την εξέλιξη του δυναμικού της μεμβράνης κάθε νευρώνα, καθώς και τον μηχανισμό παραγωγής αιχμών ως μαθηματικά μοντέλα. Ωστόσο, θεωρείται μέχρι σήμερα αρκετά απαιτητική η προσομοίωση μεγάλων νευρωνικών δικτύων αιχμών με μεγάλο πλήθος συναπτικών συνδέσεων, ακόμα και με τη χρήση απλούστερων μοντέλων, όπως είναι το LIF, εξαιτίας του μεγάλου ρυθμού των γεγονότων (10^4 συναπτικά γεγονότα το δευτερόλεπτο για κάθε νευρώνα κατά μέσο όρο). Για την αντιμετώπιση του προβλήματος της υπολογιστικής πολυπλοκότητας στην προσομοίωση ΝΔΑ, έχουν αναπτυχθεί διάφορες λύσεις, από λογισμικά προσομοίωσης έως νευρομορφικό υλικό.

Λογισμικά προσομοίωσης

Υπάρχουσες προσεγγίσεις για την προσομοίωση ΝΔΑ μέσω λογισμικού μπορούν να χωριστούν σε δύο κατηγορίες: αυτές που κάνουν χρήση μιας σταθερής χρονικής ανάλυσης για την ανανέωση της νευρωνικής κατάστασης, όπως συμβαίνει με το εσωτερικό ρολόι ενός υπολογιστή, και αυτές που βασίζονται σε γεγονότα, όπως ο χρόνος άφιξης μιας αιχμής, για την τροποποίηση του δυναμικού της μεμβράνης. Η πρώτη μέθοδος, λύνει τις διαφορικές εξισώσεις που περιγράφουν την εξέλιξη του δυναμικού μεμβράνης σε συνάρτηση με το χρόνο μέσω αριθμητικής ολοκλήρωσης. Ωστόσο, εξαιτίας της ανανέωσης των εξισώσεων μόνο στους χτύπους του ρολογιού (χρονική ανάλυση κοντά στο 1 χιλιοστό του δευτερολέπτου), οι μη γραμμικές διαφορικές εξισώσεις μπορούν μόνο να προσεγγιστούν και όχι να επιλυθούν, ενώ οι χρόνοι εμφάνισης των αιχμών χάνουν την ακρίβειά τους στο χρόνο, δεδομένου ότι περιορίζονται από διακριτά χρονικά βήματα. Συγκριτικά, οι μέθοδοι που βασίζονται σε γεγονότα χαρακτηρίζονται από την ακρίβειά τους, αφού χρησιμοποιούν τις λύσεις των διαφορικών εξισώσεων των νευρωνικών μοντέλων και οι χρόνοι άφιξης των αιχμών δεν περιορίζονται σε συγκεκριμένα χρονικά παράθυρα. Ωστόσο, εκτός από τους νευρώνες του μοντέλου LIF, τα άλλα μοντέλα που παρουσιάσαμε στην ενότητα 2.3.2 είναι μη επιλύσιμα αναλυτικά. Οι ασύγχρονες αυτές προσεγγίσεις, δεν εκμεταλλεύονται τον υψηλό ρυθμό συναπτικών γεγονότων (10^4 Hz για κάθε νευρώνα) για την βελτίωση της υπολογιστικής απόδοσης. Ως εκ τούτου, τα περισσότερα δημοφιλή λογισμικά προσομοίωσης χρησιμοποιούν μία υβριδική λύση που συνδυάζει τις δύο παραπάνω μεθόδους, συμπεριλαμβανομένου του προσομοιωτή NEST [29] και Brian [30]. Σε αυτή την περίπτωση η νευρωνική κατάσταση ανανεώνεται με συγχρονισμένο τρόπο, αλλά η λειτουργία των συνάψεων βασίζεται σε γεγονότα.

Ένα άλλο εργαλείο λογισμικού ονόματι PyNN [16], αποτελεί μία γλώσσα περιγραφής για την δημιουργία Νευρωνικών Δικτύων Αιχμών. Κάνει χρήση αφηρημένων εκφράσεων για την περιγραφή λεπτομερειών από διάφορους προσομοιωτές και παρέχει ενοποιημένες Διεπαφές Προγραμματισμού Εφαρμογών (Application Programming Interfaces - APIs) για κάθε προσομοιωτή που το υποστηρίζει. Κατα συνέπεια, νευροεπιστήμονες και σχεδιαστές ΝΔΑ δεν χρειάζεται να μάθουν διαφορετικές “γλώσσες” για συγκεκριμένους προσομοιωτές, ενώ ταυτόχρονα μοντέλα που

έχουν γραφτεί με τη χρήση του PyNN μπορούν να τρέχουν ελεύθερα σε όλους τους υποστηριζόμενους προσομοιωτές. Το μοντέλο NDA που αναπτύχθηκε στα πλαίσια αυτής της εργασίας έχει περιγραφεί μέσω του εργαλείου PyNN, ενώ η λειτουργία του έχει ελεγχθεί με τη βοήθεια του νευρομορφικού υλικού SpiNNaker [24], τη λειτουργία του οποίου θα αναλύσουμε στην επόμενη υποενότητα.

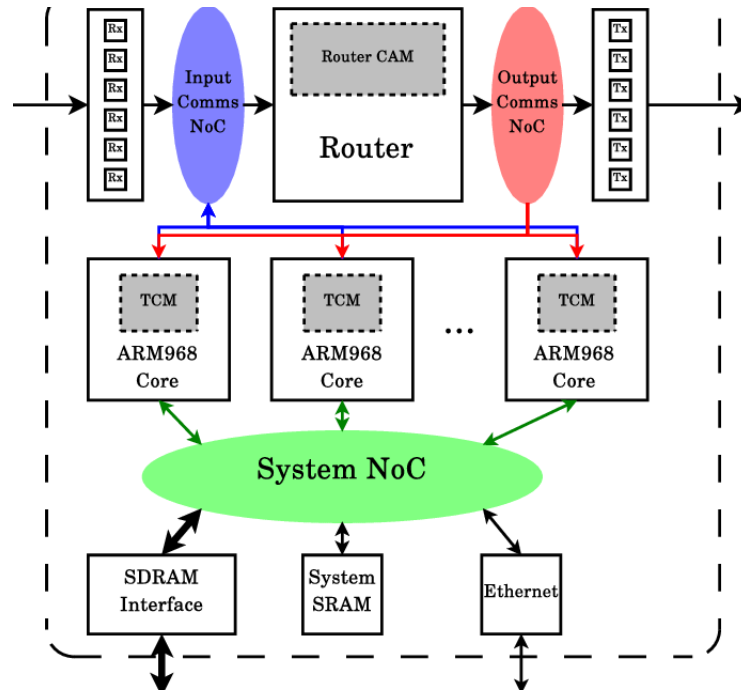
Νευρομορφικό Υλικό

Τα νευρομορφικά συστήματα μπορούν να διακριθούν σε αναλογικά, ψηφιακά και μικτής λειτουργίας (αναλογικά-ψηφιακά), ανάλογα με το πως οι νευρώνες, οι συνάψεις και η διάδοση των αιχμών υλοποιούνται. Ορισμένες αναλογικές υλοποιήσεις εκμεταλλεύονται τη δυναμική του υποκατωφλίου των τρανζίστορ για την προσομοίωση νευρώνων και συνάψεων απευθείας στο υλικό [44] με αποτέλεσμα να είναι ενεργειακά αποδοτικές και να απαιτούν λιγότερο χώρο συγκριτικά με τις αντίστοιχες ψηφιακές υλοποιήσεις [48]. Ωστόσο, η συμπεριφορά των αναλογικών κυκλωμάτων είναι δύσκολη να ελεγχθεί μέσω της διαδικασίας της κατασκευής, εξαιτίας της εμφάνισης ανομορφιών (mismatches) στα τρανζίστορ [44, 77, 60]. Παράλληλα, οι περιορισμοί που υπάρχουν στις δυνατές πυκνότητες καλωδίωσης καθιστούν τις απευθείας συνδέσεις από σημείο σε σημείο μη πρακτικές για συστήματα μεγάλης κλίμακας.


Η πλειοψηφία των νευρομορφικών συστημάτων μικτής λειτουργίας, όπως το High Input Count Analog Neural Network (HI-CANN) [88], το Neurogrid [6] και το HiAER-IFAT [111], χρησιμοποιούν αναλογικά κυκλώματα για την προσομοίωση νευρώνων και ψηφιακή τεχνολογία βασισμένη σε πακέτα (packet-based technology) για την διάδοση των αιχμών μέσω του πρωτοκόλλου Address-Event Representation (AER) [54]. Έτσι, γίνεται δυνατή η αναδιαμόρφωση των μοτίβων συνδεσιμότητας μεταξύ των νευρώνων και ικανοποιείται η απαίτηση για περιβάλλον προσομοίωσης πραγματικού χρόνου.

Οι ψηφιακές νευρομορφικές πλατφόρμες όπως το TrueNorth [71] κάνουν χρήση ψηφιακών κυκλωμάτων με πεπερασμένη ακρίβεια για την προσομοίωση νευρώνων με μεθόδους που βασίζονται σε γεγονότα, ώστε να ελαχιστοποιηθεί η εξάλειψη ενεργούς ισχύος. Τα συστήματα αυτά χαρακτηρίζονται, ακόμα, από περιορισμένη ευελιξία στην προσομοίωση νευρωνικών μοντέλων, αφού οι νευρώνες και οι συνάψεις έχουν κατασκευαστεί απευθείας στο υλικό, δίνοντας έλεγχο μόνο σε ένα μικρό υποσύνολο των παραμέτρων. Η νευρομορφική αρχιτεκτονική πολλών πυρήνων SpiNNaker [24] χρησιμοποιεί προγραμματιζόμενους πυρήνες χαμηλής ισχύος και επεκτάσιμο υλικό για την επικοινωνία των νευρώνων με βάση τα γεγονότα. Έτσι, τα νευρωνικά και συναπτικά μοντέλα μπορούν να υλοποιηθούν με τη χρήση λογισμικού. Ωστόσο, ενώ η μοντελοποίηση μέσω λογισμικού προσφέρει εξαιρετική ευελιξία, οι ψηφιακές πλατφόρμες έχουν γενικά μειωμένη ακρίβεια εξαιτίας της εγγενούς διακριτοποίησης και υψηλότερη κατανάλωση ενέργειας συγκριτικά με τις αναλογικές πλατφόρμες.

Τα ολοκληρωμένα κυκλώματα ειδικών εφαρμογών (Application-Specific Integrated Circuit - ASIC), όπως το σύστημα SpiNNaker είναι από τις πιο δημοφιλείς υλοποιήσεις νευρομορφικού υλικού [92]. Το SpiNNaker χρησιμοποιεί μία αρχιτεκτονική υψηλού παραλληλισμού (Σχήμα 2.17) για την αποδοτική προσομοίωση νευρωνικών δικτύων αιχμών μεγάλης κλίμακας. Πιο συγκεκριμένα, δεν κάνει χρήση τεχνητών νευρώνων πυριτίου πάνω στο τσιπ, αλλά βασίζεται σε κανονικούς επεξεργαστές για να διατηρήσει την ευελιξία και επεκτασιμότητα των παραδοσιακών υπολογιστών. Την ίδια στιγμή αποφεύγει τη συμφόρηση στο δίαυλο μεταφοράς δεδομένων (Von Neumann's bottleneck) όταν προσομοιώνονται μεγάλοι αριθμοί νευρώνων. Μία πλακέτα SpiNNaker τεσσάρων κόμβων αποτελείται από 64 επεξεργαστές, ενώ μπορεί να προσομοιώσει πάνω από 10.000 νευρώνες.



Σχήμα 2.17: Η αρχιτεκτονική του νευρομορφικού υπολογιστικού συστήματος SpiNNaker [83]. Οι διακεκομμένες γραμμές υποδεικνύουν την έκταση του τσιπ που ορίζει η αρχιτεκτονική SpiNNaker, ενώ τα γκρι κουτιά τις τοπικές περιοχές μνήμης.



Σχήμα 2.18: Εσωτερική όψη πλακέτας 48 κόμβων του νευρομορφικού συστήματος SpiNNaker [83].



Σχήμα 2.19: Το νευρομορφικό σύστημα SpiNNaker του Human Brain Project στο Μάντσεστερ του Ηνωμένου Βασιλείου [83].



Σχήμα 2.20: Εξωτερική όψη πλακέτας 48 κόμβων του νευρομορφικού συστήματος SpiNNaker [83].

Κεφάλαιο 3

Τεχνικό Υπόβαθρο

"If the mind was simple enough for us to understand, we would be too simple to understand it."

— Ray Kurzweil

Σε αυτό το Κεφάλαιο θα παρουσιάσουμε τα διαφορετικά εργαλεία και τις τεχνολογίες που χρησιμοποιήθηκαν για την υλοποίηση του συστήματος. Η αναφορά τους θα γίνει στη σειρά με την οποία εμφανίστηκαν κατά τη διάρκεια πραγματοποίησης της εργασίας.

3.1 Τεχνολογίες Προεπεξεργασίας Δεδομένων

3.1.1 General Data Format - GDF

Υπάρχουν πολλοί τύποι αρχείων στους οποίους τα βιοϊατρικά σήματα, που έχουν καταγραφεί, αποθηκεύονται. Οι περισσότερες μορφές αρχείων έχουν αναπτυχθεί για έναν συγκεκριμένο σκοπό μίας εξειδικευμένης κοινότητας ενός επιστημονικού κλάδου, όπως η έρευνα του Ηλεκτροεγκεφαλογραφήματος ή η ανάλυση του Ηλεκτροκαρδιογραφήματος. Πριν την εμφάνιση του προτύπου GDF, κανένα από τα υπάρχοντα μορμάτ δεν μπορούσε να θεωρηθεί πως αποτελεί ένα γενικού σκοπού μορμάτ δεδομένων για βιοϊατρικά σήματα. Για την επίλυση αυτού του προβλήματος και την ενοποίηση των αναγκών των διαφόρων πεδίων της επεξεργασίας βιοϊατρικών σημάτων, αναπτύχθηκε το πλήρως ορισμένο General Data Format - GDF. Το λογισμικό για την ανάγνωση και την επεξεργασία δεδομένων τύπου GDF έχει υλοποιηθεί στα προγράμματα Matlab/Octave και προσφέρεται μέσα από την εργαλειοθήκη ανοιχτού κώδικα BioSig, που θα αναλύσουμε στη συνέχεια [89]. Τα δεδομένα που θα χρησιμοποιήσουμε στα πλαίσια αυτής της εργασίας προσφέρονται στην μορφή GDF.

Τα περισσότερα μορμάτ δεδομένων απευθύνονται σε συγκεκριμένες ανάγκες μεμονωμένων εφαρμογών, αλλά κανένα δεν είναι αρκετά ευέλικτο για να ικανοποιήσει τις νέες ανάγκες στο πεδίο της καταγραφής ΗΕΓ και της έρευνας των Διεπαφών Εγκεφάλου-Υπολογιστή. Το μορμάτ GDF έχει επιτυχώς υλοποιηθεί και χρησιμοποιηθεί στην έρευνα των ΔΕΥ. Παρέχει ένα κοινό σχήμα κωδικοποίησης για τα γεγονότα, ενώ υποστηρίζει αρκετά χρήσιμα χαρακτηριστικά, όπως διαφορετικοί ρυθμοί δειγματοληψίας, βαθμονόμηση τιμών για διαφορετικά κανάλια και αυτόματη ανίχνευση υπερχείλισης. Αναλυτικός προσδιορισμός του προτύπου μπορεί να βρεθεί στην βιβλιογραφία [89].

3.1.2 Εργαλειοθήκη BioSig

Η εργαλειοθήκη BioSig αποτελεί μία βιβλιοθήκη λογισμικού ανοιχτού κώδικα για την επεξεργασία βιοϊατρικών σημάτων, όπως το Ηλεκτροεγκεφαλογράφημα (ΗΕΓ), το Ηλεκτροκορτικογράφημα, το Ηλεκτροκαρδιογράφημα (ΗΚΓ), το Αμφιβληστροειδογράφημα, το Ηλεκτρομυογράφημα (ΗΜΓ) και άλλα. Οι βασικές περιοχές εφαρμογής είναι η Νευροπληροφορική, οι Διεπαφές Εγκεφάλου-Υπολογιστή, η Νευροφυσιολογία, η Ψυχολογία και τα καρδιαγγειακά συστήματα. Ο στόχος του προγράμματος BioSig είναι η υποβοήθηση της έρευνας στο πεδίο της επεξεργασίας βιοϊατρικών σημάτων, προσφέροντας εργαλεία λογισμικού ανοιχτού κώδικα για μία πληθώρα από εφαρμογές. Το BioSig απευθύνεται στα διάφορα προβλήματα που υπάγεται αυτός ο επιστημονικός κλάδος, παρέχοντας λύσεις για την απόκτηση δεδομένων, την επεξεργασία των ατελειών (artifacts) και τον έλεγχο της ποιότητας των δεδομένων, την εξαγωγή χαρακτηριστικών, την μοντελοποίηση και οπτικοποίηση δεδομένων [102].

Το εργαλείο BioSig χρησιμοποιήθηκε σε συνδυασμό με το υπολογιστικό περιβάλλον Matlab, για την επεξεργασία των διαθέσιμων δεδομένων στη μορφή GDF και την μετατροπή τους σε αρχεία τύπου MAT, διατηρώντας όλη την πληροφορία που διέθεταν αρχικά, με τη χρήση κατάλληλων βιβλιοθηκών και εντολών.

3.1.3 MNE-Python

Το λογισμικό MNE-Python είναι ένα πακέτο ανοιχτού κώδικα της γλώσσας προγραμματισμού Python που χρησιμοποιείται για την ανάγνωση, οπτικοποίηση και ανάλυση ανθρώπινων νευροφυσιολογικών δεδομένων, όπως τα ΗΕΓ, ΗΜΓ και ΗΚΓ. Η χρήση αυτών των σημάτων για τον χαρακτηρισμό και τον εντοπισμό της νευρωνικής ενεργοποίησης στον ανθρώπινο εγκέφαλο αποτελεί ένα αρκετά δύσκολο έργο. Το MNE απευθύνεται σε αυτές τις προκλήσεις προσφέροντας αλγορίθμους υλοποιημένους στην γλώσσα Python που καλύπτουν πολλαπλές μεθόδους επεξεργασίας δεδομένων, στατιστικής ανάλυσης και εκτίμησης της λειτουργικής συνδεσιμότητας μεταξύ των εγκεφαλικών περιοχών. Επιπρόσθετα, είναι στενά συνδεδεμένο με βασικές βιβλιοθήκες της Python για επιστημονικούς υπολογισμούς, όπως οι NumPy και SciPy, αλλά και εργαλεία οπτικοποίησης, όπως το matplotlib. Τέλος, δίνεται πρόσβαση σε προεπεξεργασμένα σύνολα δεδομένων, συμπεριλαμβανομένου και του συνόλου που χρησιμοποιήθηκε στην παρούσα εργασία [31].

Η βιβλιοθήκη MNE της Python χρησιμοποιήθηκε για την μετατροπή των δεδομένων από τον τύπο αρχείων .MAT στην μορφή .FIF, η οποία θα αναλυθεί στην συνέχεια, διατηρώντας όλη την πληροφορία που διέθεταν στην αρχική τους μορφή, αλλά και για την οπτικοποίησή τους πριν από την προεπεξεργασία.

3.1.4 Functional Image File Format - FIFF

Το πρότυπο FIF δημιουργήθηκε αρχικά για την χρήση του στα δεδομένα που παράγονταν από το σύστημα Neuromag της Elekta¹. Έχει αναπτυχθεί ώστε να είναι συμβατό με όλα τα διαφορετικά βιοϊατρικά σήματα που συναντώνται σε εφαρμογές του αντίστοιχου κλάδου. Η βασική δομή των δεδομένων που ορίζει, επιτρέπει την αναπαράσταση σχεδόν κάθε συλλογής δυαδικών δεδομένων. Οι μόνοι περιορισμοί που επιβάλλονται είναι από τα κανονικοποιημένα σύνολα "ετικετών" και "τύπων", που χρησιμοποιούνται για την ερμηνεία των διαφορετικών στοιχείων των δεδομένων, αλλά και για την περιγραφή της κωδικοποίησής τους.

Μετά την μετατροπή των αρχείων σε μορφή .MAT, έγινε χρήση του λογισμικού MNE της Python, για την δημιουργία των τελικών δεδομένων σε μορφή .FIF. Τα διαθέσιμα σήματα ΗΕΓ που υπέστησαν προεπεξεργασία και μετέπειτα εξαγωγή χαρακτηριστικών ακολουθούσαν το συ-

¹<https://www.elekta.com/diagnostic-solutions/elekta-neuromag-triux/>

γκεκριμένο πρότυπο. Περισσότερες λεπτομέρειες σχετικά με την οργάνωση του προτύπου μπορεί κανείς να βρεί στο αντίστοιχο έγγραφο προδιαγραφών ².

3.2 Εργαλεία Εξαγωγής Χαρακτηριστικών

3.2.1 Βιβλιοθήκη NumPy

Στην γλώσσα προγραμματισμού Python, οι πίνακες τύπου NumPy αποτελούν την τυπική αναπαράσταση νουμερικών δεδομένων. Στα μέσα της δεκαετίας του 90', μία διεθνής ομάδα εθελοντών ξεκίνησαν να αναπτύσσουν μία δομή δεδομένων για τον αποδοτικό υπολογισμό πινάκων. Αυτή η δομή εξελίχθηκε σε αυτό που τώρα ονομάζουμε N -διάστατο πίνακα NumPy. Το πακέτο NumPy, που χρησιμοποιήσαμε, αποτελείται από τη δομή πινάκων NumPy, αλλά και από ένα ευρύ σύνολο μαθηματικών συναρτήσεων και έχει υοθετηθεί από πολυάριθμες ερευνητικές ομάδες στον ακαδημαϊκό τομέα, εθνικά εργαστήρια και την βιομηχανία. Ένας πίνακας NumPy είναι μία πολυδιάστατη ομοιόμορφη συλλογή από στοιχεία. Ένας τέτοιος πίνακας χαρακτηρίζεται από τον τύπο των στοιχείων του και από το σχήμα του. Σε αντίθεση με τους παραδοσιακούς πίνακες (μήτρες), οι πίνακες NumPy, μπορούν να έχουν οποιαδήποτε διάσταση, ενώ μπορούν να περιέχουν διαφορετικούς τύπους στοιχείων ή και συνδυασμούς από στοιχεία [104].

Η βιβλιοθήκη NumPy χρησιμοποιήθηκε σε συνδυασμό με το πακέτο Signal της βιβλιοθήκης SciPy, για την εξαγωγή χαρακτηριστικών από τα δεδομένα σε μορφή FIF. Πιο συγκεκριμένα, οι διαφορετικές μαθηματικές συναρτήσεις που ορίζουν τις μεθόδους εξαγωγής χαρακτηριστικών που αναλύθηκαν στην Ενότητα 4.2, υλοποιήθηκαν με τη χρήση κατάλληλων εντολών που παρέχονται από τα εργαλεία NumPy και SciPy. Τα τελικά χαρακτηριστικά που προέκυψαν και χρησιμοποιήθηκαν για την εκπαίδευση του Νευρωνικού Δικτύου Αιχμών είναι σε μορφή πινάκων NumPy.

3.2.2 Βιβλιοθήκη SciPy

Το SciPy είναι μία βιβλιοθήκη νουμερικών συναρτήσεων της γλώσσας προγραμματισμού Python, που προσφέρει τα θεμελιώδη εργαλεία για την μοντελοποίηση και επίλυση επιστημονικών προβλημάτων. Περιλαμβάνει αλγόριθμους για προβλήματα βελτιστοποίησης, αλγεβρικών και διαφορικών εξισώσεων, ολοκλήρωσης, παρεμβολής και άλλα. Έχει δημιουργηθεί πάνω από τη βιβλιοθήκη NumPy της Python και αποτελεί την βάση πάνω στην οποία έχουν αναπτυχθεί υψηλότερου επιπέδου βιβλιοθήκες, όπως τα scikit-learn και scikit-image [103].

Η εργαλειοθήκη της βιβλιοθήκης SciPy για επεξεργασία σημάτων, SciPy.Signal ³, περιέχει συναρτήσεις φιλτραρίσματος σημάτων, εργαλεία σχεδίασης φίλτρων και ορισμένους αλγόριθμους παρεμβολής για μονοδιάστατα και διδιάστατα δεδομένα. Τα δεδομένα που επεξεργάζεται το πακέτο, όπως και τα διαθέσιμα σήματα ΗΕΓ που θα χρησιμοποιήσουμε είναι ουσιαστικά πίνακες από πραγματικούς αριθμούς. Όπως σημειώσαμε και προηγουμένως, το πακέτο SciPy.Signal χρησιμοποιήθηκε για την υλοποίηση των διάφορων μεθόδων επεξεργασίας και εξαγωγής χαρακτηριστικών. Η διαδικασία υλοποίησης περιγράφεται αναλυτικά στην Ενότητα 6.2.

²<https://www.dropbox.com/s/q58whpso2jt9tx0/Fiff.pdf?dl=0>

³<https://docs.scipy.org/doc/scipy/reference/tutorial/signal.html>

3.3 Προσομοίωση Νευρωνικών Δικτύων Αιχμών σε Νευρομορφικό Υλικό

3.3.1 Human Brain Project

Το Human Brain Project ⁴ (HBP) είναι ένα μεγάλης κλίμακας ερευνητικό πρόγραμμα συνολικής διάρκειας δέκα ετών, που στοχεύει να χτίσει μία συνεργατική υποδομή επιστημονικής έρευνας η οποία θα επιτρέψει σε ερευνητές της Ευρώπης να προάγουν την ανάπτυξη στους κλάδους της Νευροεπιστήμης, της Επιστήμης των Υπολογιστών και της Βιοϊατρικής. Το πρόγραμμα ξεκίνησε το 2013, συντονίζεται από την Ομοσπονδιακή Πολυτεχνική Σχολή της Λωζάνης και χρηματοδοτείται κυρίως από την Ευρωπαϊκή Ένωση. Θεμελιώδης κρίνεται για την προσέγγιση του HBP είναι η εξερεύνηση του ανθρώπινου εγκεφάλου σε διαφορετικές χωρικές και χρονικές κλίμακες (από το μοριακό επίπεδο σε μεγάλα νευρωνικά δίκτυα υπεύθυνα για υψηλότερες γνωστικές διαδικασίες και από την τάξη του χιλιοστού του δευτερολέπτου σε έτη). Για την επίτευξη αυτού του σκοπού, το HBP βασίζεται στην συνεργασία επιστημόνων από διάφορες ειδικότητες, όπως η Νευροεπιστήμη, η Φιλοσοφία και η Επιστήμη των Υπολογιστών, για την εκμετάλλευση των διαθέσιμων πειραματικών δεδομένων, θεωριών μοντελοποίησης και μεθόδων προσομοίωσης. Η ιδέα είναι πως τα εμπειρικά δεδομένα χρησιμοποιούνται για την ανάπτυξη θεωριών, οι οποίες πυροδοτούν την μοντελοποίηση και τις προσομοιώσεις οι οποίες καταλήγουν σε προβλέψεις που επαληθεύονται από τα εμπειρικά αποτελέσματα.

Το ερευνητικό πρόγραμμα χωρίζεται σε 12 υποπρογράμματα, τα 6 από τα οποία αναπτύσσουν υπολογιστικές πλατφόρμες, οι οποίες αποτελούνται από προτότυπο υπολογιστικό υλικό, λογισμικό, βάσεις δεδομένων και προγραμματιστικές διεπαφές. Αυτά τα εργαλεία είναι διαθέσιμα σε ερευνητές παγκοσμίως μέσω του HBP Collaboratory ⁵. Τα τρία από τα υπόλοιπα υποπρογράμματα συλλέγουν δεδομένα μέσω εμπειρικής Νευροεπιστήμης και καθιερώνουν θεωρητικές βάσεις, ενώ το υποπρόγραμμα 12 είναι υπεύθυνο για την ηθική βάση των παραπάνω έργων. Το υποπρόγραμμα 11 συντονίζει το συνολικό ερευνητικό πρότζεκτ.

Η πλατφόρμα που χρησιμοποιήσαμε για την υλοποίηση του συστήματος της παρούσας εργασίας ανήκει στο υποπρόγραμμα 9 και ονομάζεται Πλατφόρμα Νευρομορφικής Υπολογιστικής (Neuromorphic Computing Platform), στα πλαίσια της οποίας αναπτύσσονται και υλοποιούνται τεχνολογίες Νευρομορφικής Υπολογιστικής. Το υποπρόγραμμα αυτό είναι υπεύθυνο για την πραγμάτωση δύο σημαντικών δραστηριοτήτων:

- Κατασκευή δύο προτότυπων νευρομορφικών μηχανών μεγάλης κλίμακας
- Δημιουργία νευρομορφικών ολοκληρωμένων κυκλωμάτων επόμενης γενιάς

Οι δύο νευρομορφικοί υπολογιστές που έχουν υλοποιηθεί βασίζονται σε δύο συμπληρωματικές αρχές. Η μηχανή SpiNNaker πολλών πυρήνων που βρίσκεται στο Μάντσεστερ του Ηνωμένου Βασιλείου, συνδέει ένα εκατομμύριο επεξεργαστές ARM με ένα δίκτυο που βασίζεται στην ανταλλαγή πακέτων και έχει βελτιστοποιηθεί για την διαβίβαση νευρωνικών δυναμικών δράσης (αιχμές). Η μηχανή BrainScaleS που βρίσκεται στην Χαϊδελβέργη της Γερμανίας υλοποιεί αναλογικά ηλεκτρονικά μοντέλα τεσσάρων εκατομμυρίων νευρώνων και ενός δισεκατομμυρίου συνάψεων σε 20 πλακέτες (wafers) σιλικόνης. Τόσο το σύστημα SpiNNaker όσο και το BrainScaleS, είναι ενσωματωμένα στο HBP Collaboratory και προσφέρουν πλήρη υποστήριξη λογισμικού στους χρήστες.

Το πιο επιφανές χαρακτηριστικό των νευρομορφικών μηχανών που έχουν υλοποιηθεί στα πλαίσια του Human Brain Project, είναι η ταχύτητα εκτέλεσης προσομοιώσεων σε αυτές. Το σύστημα SpiNNaker εκτελείται σε πραγματικό χρόνο, ενώ το BrainScaleS είναι υλοποιημένο ως σύστημα επιτάχυνσης και εκτελείται σε χρόνο 10.000 φορές μεγαλύτερο από τον πραγματικό. Οι προσομοιώσεις σε συμβατικούς υπερυπολογιστές τυπικά εκτελούνται 1000 φορές πιο αργά από

⁴<https://www.humanbrainproject.eu/en/>

⁵<https://collab.humanbrainproject.eu/>

ότι στα βιολογικά συστήματα, ενώ είναι αδύνατο να έχουν πρόσβαση στις μεγαλύτερες κλίμακες χρόνου που συμμετέχουν σε διαδικασίες μάθησης και ανάπτυξης, που κυμαίνονται από χιλιοστά του δευτερολέπτου σε χρόνια.

3.3.2 Η γλώσσα περιγραφής Νευρωνικών Δικτύων PyNN

Το PyNN είναι μία γλώσσα περιγραφής μοντέλων Νευρωνικών Δικτύων Αιχμών ανοιχτού κώδικα, βασισμένη στην γλώσσα προγραμματισμού Python και ανεξάρτητη από τον προσομοιωτή που χρησιμοποιείται. Μπορεί, δηλαδή, κανείς να γράψει τον κώδικα ενός μοντέλου χρησιμοποιώντας την προγραμματιστική διεπαφή του PyNN και την γλώσσα Python, και έπειτα να το εκτελέσει σε οποιονδήποτε προσομοιωτή υποστηρίζει το PyNN (NEURON, NEST και Brian), αλλά και σε έναν μεγάλο αριθμό συστημάτων νευρομορφικού υλικού, συμπεριλαμβανομένου και του SpiNNaker [16]. Η διεπαφή του PyNN υποστηρίζει την μοντελοποίηση δικτύων σε ένα υψηλό επίπεδο αφάιρησης, ενώ ταυτόχρονα επιτρέπει την πρόσβαση στις λεπτομέρειες μεμονωμένων νευρώνων και συνάψεων, όταν αυτό απαιτείται. Παρέχει μία βιβλιοθήκη από βασικά μοντέλα νευρώνων, συνάψεων και συναπτικής πλαστικότητας, τα οποία έχουν επαληθευτεί πως παρουσιάζουν κοινή συμπεριφορά στους διαφορετικούς προσομοιωτές [16]. Στην παρούσα εργασία έγινε χρήση της γλώσσας PyNN για την προσομοίωση του Νευρωνικού Δικτύου Αιχμών που αναλύσαμε στην Ενότητα 4.3, σε συνδυασμό με το πακέτο sPyNNaker της γλώσσας Python, το οποίο θα αναλύσουμε στην συνέχεια.

Τα βασικά βήματα που χρειάζεται κανείς να ακολουθήσει για την δημιουργία ενός δικτύου PyNN περιγράφονται ακολούθως:

1. Ρύθμιση των παραμέτρων του προσομοιωτή/νευρομορφικού συστήματος.
2. Δημιουργία των νευρωνικών πληθυσμών.
3. Δημιουργία των προβολών μεταξύ των πληθυσμών.
4. Ρύθμιση των παραμέτρων καταγραφής δεδομένων.
5. Εκτέλεση της προσομοίωσης.
6. Ανάκτηση και επεξεργασία των καταγεγραμμένων δεδομένων.

Παρατίθεται ένα παράδειγμα των παραπάνω βημάτων:

```

1 import pyNN.spiNNaker as sim
2 import pyNN.utility.plotting as plot
3 import matplotlib.pyplot as plt
4
5 sim.setup(timestep=1.0)
6 sim.set_number_of_neurons_per_core(sim.IF_curr_exp, 100)
7
8 pop_1 = sim.Population(1, sim.IF_curr_exp(), label="pop_1")
9 input = sim.Population(1, sim.SpikeSourceArray(spike_times=[0]), label="input")
10 input_proj = sim.Projection(input, pop_1, sim.OneToOneConnector(),
11                             synapse_type=sim.StaticSynapse(weight=5, delay=1))
12
13 pop_1.record(["spikes", "v"])
14 simtime = 10

```

```

15 sim.run(simtime)
16
17 neo = pop_1.get_data(variables=["spikes", "v"])
18 spikes = neo.segments[0].spiketrains
19 print spikes
20 v = neo.segments[0].filter(name='v')[0]
21 print v
22 sim.end()
23
24 plot.Figure(
25     # plot voltage for first ([0]) neuron
26     plot.Panel(v, ylabel="Membrane potential (mV)",
27         data_labels=[pop_1.label], yticks=True, xlim=(0, simtime)),
28     # plot spikes (or in this case spike)
29     plot.Panel(spikes, yticks=True, markersize=5, xlim=(0, simtime)),
30     title="Simple Example",
31     annotations="Simulated with {}".format(sim.name())
32 )
33
34 plt.show()

```

Η παραπάνω προσομοίωση εκτελείται με χρονικό βήμα $timestep = 1.0 \text{ ms}$. Δημιουργεί μία πηγή εισόδου (*SpikeSourceArray*), η οποία στέλνει μία αιχμή σε χρόνο 0 ms και συνδέεται με έναν νευρώνα μοντέλου *IF_curr_exp*. Η σύνδεση είναι ζυγισμένη, έτσι ώστε μία αιχμή στον προσυναπτικό νευρώνα να στέλνει ένα στατικό ρεύμα πλάτους 5 nA στην διεγερτική σύναψη του μετασυναπτικού νευρώνα με καθυστέρηση 1 ms . Στη συνέχεια καταγράφονται οι αιχμές και το δυναμικό μεμβράνης για τη διάρκεια της προσομοίωσης των 10 ms . Τέλος, σχεδιάζονται κατάλληλα γραφήματα που αναπαριστούν την εξέλιξη των καταγεγραμμένων τιμών.

Πληθυσμοί και μοντέλα νευρώνων

Στο PyNN, η δήλωση των νευρώνων γίνεται μέσω του ορισμού ενός πληθυσμού από νευρώνες με όμοιες ιδιότητες. Η γλωσσα PyNN προσφέρει έναν αριθμό από βασικά μοντέλα νευρώνων. Στο παραπάνω παράδειγμα κάναμε χρήση του μοντέλου *Leaky Integrate-and-Fire (IF_curr_exp)*, το οποίο είναι και το μοντέλο των νευρώνων του δικτύου που υλοποιήθηκε. Όπως είχαμε αναφέρει στην Ενότητα 2.3.3, σε αυτό το μοντέλο ένας νευρώνας ορίζεται από μία αντίσταση και έναν πυκνωτή συνδεδεμένα παράλληλα. Όσο εισέρχεται ρεύμα, ο πυκνωτής φορτίζεται, ενώ ταυτόχρονα διαρρέει ηλεκτρικό φορτίο από την αντίσταση. Επιπλέον, ορίζεται μία τιμή δυναμικού κατωφλίου. Εάν το δυναμικό φτάσει αυτή την τιμή, παράγεται μία αιχμή. Για ένα χρονικό διάστημα μετά από την αιχμή, γνωστό ως ανερέθιστη περίοδος, ο νευρώνας δεν μπορεί να παράξει άλλη αιχμή. Όταν αυτή η περίοδος περάσει, ο νευρώνας συνεχίζει τη λειτουργία του όπως προηγουμένως. Οι σνάψεις μοντελοποιούνται με τη χρήση μίας φθίνουσας εκθετικής σταθεράς που χαρακτηρίζει το εισερχόμενο ρεύμα εισόδου, το οποίο στο παράδειγμα είναι 5 nA . Έτσι, κατά τη διάρκεια ενός αριθμού από χρονικά βήματα, το ρεύμα φθίνει εκθετικά στα μεταξύ τους διαστήματα. Μεγαλύτερος ρυθμός μείωσης οδηγεί στην ενσωμάτωση περισσότερου ηλεκτρικού φορτίου συνολικά σε κάθε αιχμή που διαπερνά μία σύναψη.

Στο παράδειγμα που χρησιμοποιήσαμε, οι αρχικές παράμετροι του μοντέλου *IF_curr_exp* είναι:

```
1 'cm': 1.0, # Η χωρητικότητα του νευρώνα σε νανοφαράντ
```

- 2 `'tau_m': 20.0, #` Η χρονική σταθερά του κυκλώματος σε χιλιοστά του δευτερολέπτου
- 3 `'tau_refrac': 0.1, #` Η ανερέθιστη περίοδος σε χιλιοστά του δευτερολέπτου
- 4 `'v_reset': -65.0, #` Η τιμή του δυναμικού επανεκκίνησης
- 5 `'v_rest': -65.0, #` Η τιμή του δυναμικού ηρεμίας
- 6 `'v_thresh': -50.0, #` Η τιμή του δυναμικού κατωφλίου
- 7 `'tau_syn_E': 5.0, #` Η χρονική σταθερά μείωσης του διεγερτικού ρεύματος εισόδου
- 8 `'tau_syn_I': 5.0, #` Η χρονική σταθερά μείωσης του ανασταλτικού ρεύματος εισόδου
- 9 `'i_offset': 0.0, #` Η τιμή του ρεύματος που προστίθεται σε κάθε χρονικό βήμα

Αξίζει να σημειωθεί πως το PyNN υποστηρίζει τόσο μοντέλα που εξαρτώνται από το ρεύμα όσο και αντίστοιχα μοντέλα που εξαρτώνται από την αγωγιμότητα. Στα μοντέλα αγωγιμότητας, η είσοδος μετρίεται σε *microSiemens*, ενώ η επίδραση του δυναμικού μεμβράνης ποικίλει. Όσο μεγαλύτερη τιμή έχει το δυναμικό μεμβράνης, τόσο περισσότερη είσοδος απαιτείται για την πρόκληση αιχμής. Αυτό μοντελοποιείται ως το δυναμικό αντιστροφής (reversal potential) της σύναψης. Όταν το δυναμικό μεμβράνης ισούται με το δυναμικό αντιστροφής, το ρεύμα που διαρρέει την σύναψη είναι μηδενικό. Στο PyNN μπορούμε να βρούμε τον ορισμό του μοντέλου LIF που βασίζεται στην αγωγιμότητα, το οποίο εκτός από τις παραπάνω παραμέτρους, υποστηρίζει και τις ακόλουθες:

- 1 `'e_rev_E': 0., #` Η τιμή του δυναμικού αντιστροφής της διεγερτικής σύναψης
- 2 `'e_rev_I': -80.0 #` Η τιμή του δυναμικού αντιστροφής της ανασταλτικής σύναψης

Οι αρχικές τιμές των μεταβλητών κατάστασης του νευρωνικού μοντέλου, όπως το δυναμικό μεμβράνης, μπορούν να οριστούν μέσω της συνάρτησης *initialize*, η οποία λαμβάνει ως όρισμα το όνομα της μεταβλητής, για παράδειγμα *v* για το δυναμικό μεμβράνης, και την τιμή που θέλουμε να της αναθέσουμε, για παράδειγμα -65 mV .

```
1 pop.initialize(v=-65.0)
```

Εκτός από τα νευρωνικά μοντέλα, η γλώσσα PyNN υποστηρίζει μερικά βοηθητικά μοντέλα, τα οποία μπορούν να χρησιμοποιηθούν για την προσομοίωση της εισόδου του δικτύου με προκαθορισμένα χαρακτηριστικά. Στην εργασία θα κάνουμε χρήση των παρακάτω υποστηρικτικών μοντέλων:

- **SpikeSourceArray:** Η δομή αυτή στέλνει αιχμές σε προκαθορισμένα διαστήματα, τα οποία ορίζονται από την μεταβλητή *spike_times*. Το PyNN εξαναγκάζει κάθε νευρώνα του πληθυσμού να παράξει αιχμή την ίδια στιγμή. Συνεπώς, η μεταβλητή *spike_times* αποτελεί έναν πίνακα από χρόνους. Ωστόσο, όταν γίνεται χρήση του SpiNNaker, η δομή *spike_times* μπορεί να έχει τη μορφή ενός πίνακα από πίνακες, με τον καθένα να ορίζει τους χρόνους στους οποίους κάθε νευρώνας πρέπει να παράξει αιχμή.
- **SpikeSourcePoisson:** Η δομή αυτή στέλνει αιχμές σε τυχαίους χρόνους με μέσο όρο *rate* αιχμές ανά δευτερόλεπτο, ξεκινώντας σε χρόνο *start* (προεπιλεγμένη τιμή 0.0 ms) και για διάρκεια *duration* σε χιλιοστά του δευτερολέπτου (προεπιλεγμένη τιμή η διάρκεια όλης της προσομοίωσης).

Προβολές και Συνδέτες

Πληθυσμοί νευρώνων ενώνονται μεταξύ τους με τη χρήση προβολών (projections). Μία προβολή αποτελεί μία κατευθυνόμενη σύνδεση στην οποία διαβιβάζονται αιχμές από από έναν πληθυσμό πηγή σε έναν άλλο πληθυσμό στόχο. Η προβολή που ενώνει πληθυσμούς από νευρώνες έχει έναν συνδέτη (connector), ο οποίος περιγράφει την συνδεσιμότητα μεταξύ των μεμονωμένων νευρώνων στους πληθυσμούς. Ορισμένοι τυπικοί συνδέτες είναι:

- **OneToOneConnector:** Κάθε προσυναπτικός νευρώνας συνδέεται με έναν μετασυναπτικό νευρώνα (απαιτεί τον ίδιο αριθμό νευρώνων σε κάθε πληθυσμό).
- **AllToAllConnector:** Όλοι οι προσυναπτικοί νευρώνες συνδέονται με όλους τους μετασυναπτικούς νευρώνες.
- **FixedProbabilityConnector:** Κάθε προσυναπτικός νευρώνας συνδέεται με κάθε μετασυναπτικό νευρώνα με σταθερή πιθανότητα που ορίζεται από την μεταβλητή *p_connect*.
- **FromListConnector:** Η ακριβής συνδεσιμότητα περιγράφεται από τη δομή *conn_list*, η οποία αποτελεί μία λίστα από πλειάδες της μορφής (*pre_synaptic_neuron_id*, *post_synaptic_neuron_id*, *weight*, *delay*). Οι μεταβλητές *weight* και *delay* είναι προεραϊτικές. Εάν συμπεριληφθούν, οι αντίστοιχες τιμές που ορίζονται με βάση την παράμετρο *synapse_type* της προβολής αγνοούνται.
- **FixedTotalNumberConnector:** Δημιουργείται ένας ακριβής αριθμός από συνδέσεις *n_synapses*, οι οποίες ενώνουν τυχαία συγκεκριμένους νευρώνες. Σημειώνεται πως ορισμένες συνδέσεις μπορούν να επαναληφθούν.

Όμοια με τον συνδέτη, έτσι και η προβολή πρέπει να χαρακτηρίζεται από έναν τύπο *synapse_type*, ο οποίος καθορίζει το πως η σύναψη συμπεριφέρεται όταν διαρρέεται από μία αιχμή. Για παράδειγμα, μία σύναψη τύπου *StaticSynapse* η οποία έχει προκαθορισμένο βάρος και καθυστέρηση, μπορεί να οριστεί με τον ακόλουθο τρόπο:

```
1 synapse_type=sim.StaticSynapse(weight=0.75, delay=1.0)
```

Τυχαίες Παράμετροι

Συνήθως, χρησιμοποιούνται τυχαία βάρη και/ή καθυστερήσεις στους ορισμούς των συνάψεων ενός δικτύου. Αυτό γίνεται, με τον ορισμό της τιμής της παραμέτρου *weight* ή *delay* του τύπου της σύναψης σε *RandomDistribution*. Σημειώνεται πως σε αυτή την περίπτωση ο συνδέτης τύπου *FromListConnector* δεν θα πρέπει να περιέχει επιπλέον ορισμούς των ίδιων παραμέτρων. Η δομή *RandomDistribution* υποστηρίζει διάφορες παραμέτρους μέσω του ορίσματος *parameters*, ανάλογα με την τιμή του ορίσματος *distribution*, με το οποίο ορίζεται ο τύπος της κατανομής. Οι υποστηριζόμενες κατανομές περιλαμβάνουν την ομοιόμορφη κατανομή *uniform*, με παραμέτρους *low* και *high*, που καθορίζουν την ελάχιστη και μέγιστη τιμή αντίστοιχα, την κανονική κατανομή *normal*, με παραμέτρους *mu* και *sigma*, που καθορίζουν τον μέσο όρο και την τυπική απόκλιση αντίστοιχα, καθώς και την κατανομή *normal_clipped*, με παραμέτρους *low*, *high*, *mu* και *sigma*. Η *RandomDistribution* μπορεί να χρησιμοποιηθεί ακόμα, στον προσδιορισμό των νευρωνικών παραμέτρων ή στην αρχικοποίηση των μεταβλητών κατάστασης.

Καταγραφή δεδομένων

Όλοι οι πληθυσμοί σε μία προσομοίωση μπορούν να καταγραφούν, με τα δεδομένα που είναι δυνατό να καταγραφούν κάθε φορά να εξαρτώνται από το μοντέλο της προσομοίωσης. Γενικά, όλα τα μοντέλα νευρώνων στο PyNN επιτρέπουν την καταγραφή των χρόνων στους οποίους κάθε νευρώνας παράγει αιχμές μέσω του πίνακα *spikes*, καθώς και του δυναμικού της μεμβράνης μέσω του πίνακα *v*. Αντίθετα, τα μοντέλα εισόδου, όπως τα *SpikeSourceArray* και *SpikeSourcePoisson* επιτρέπουν μόνο την καταγραφή των αιχμών. Όταν εκτελούμε προσομοιώσεις στον SpiNNaker, τα νευρωνικά μοντέλα επιτρέπουν επιπλέον την καταγραφή της εισόδου του νευρώνα μέσω της δομής

Στο παραπάνω παράδειγμα, αρχικά δημιουργούμε τον κανόνα χρονισμού. Σε αυτή την περίπτωση είναι ο κανόνας *SpikePairRule*, το οποίο σημαίνει πως ο σχετικός χρονισμός των αιχμών που θα χρησιμοποιηθούν για την ενημέρωση των βαρών βασίζεται σε ζευγάρια από προσυναπτικές και μετασυναπτικές αιχμές. Αυτός ο κανόνας λαμβάνει τέσσερις παραμέτρους. Οι παράμετροι *tau_plus* και *tau_minus* περιγράφουν την εκθετική μείωση του βάρους υπό ενημέρωση σε σχέση με τον χρόνο μεταξύ των προσυναπτικών και μετασυναπτικών αιχμών. Σημειώνεται πως η μείωση μπορεί να είναι διαφορετική για την διέγερση, όπως ορίζεται από το *tau_plus* και για την αναστολή, όπως ορίζεται από το *tau_minus*. Οι παράμετροι *A_plus* και *A_minus* περιγράφουν το μέγιστο βάρος που προστίθεται κατά τη διάρκεια της διέγερσης ή αφαιρείται κατά τη διάρκεια της αναστολής, αντίστοιχα.

Έπειτα, ορίζουμε τον κανόνα ενημέρωσης των βαρών. Στο παράδειγμα κάνουμε χρήση κανόνα *AdditiveWeightDependence*, το οποίο σημαίνει πως το κάθε βάρος ενημερώνεται απλά προσθέτοντας στο υπάρχον βάρος. Ο κανόνας απαιτεί τον ορισμό των παραμέτρων *w_max* και *w_min*, οι οποίοι ορίζουν το μέγιστο και το ελάχιστο βάρος της σύναψης αντίστοιχα. Σημειώνεται πως το πραγματικό ποσό που προστίθεται ή αφαιρείται εξαρτάται περαιτέρω από τον χρονισμό των αιχμών, ο οποίος με τη σειρά του εξαρτάται από τον κανόνα χρονισμού.

Επιπρόσθετα, υποστηρίζεται ο κανόνας *MultiplicativeWeightDependence*, το οποίο σημαίνει πως η αλλαγή του βάρους εξαρτάται από την διαφορά μεταξύ του υπάρχοντος βάρους και του *w_max* για διέγερση, και του *w_min* για αναστολή. Η τιμή του *A_plus* και του *A_minus* μετά πολλαπλασιάζονται αντίστοιχα με αυτή την διαφορά για την μέγιστη αλλαγή βάρους. Σημειώνεται πως η πραγματική τιμή που πολλαπλασιάζεται εξαρτάται από τον κανόνα χρονισμού και τον χρόνο μεταξύ των αιχμών.

Οι κανόνες χρονισμού και ενημέρωσης των βαρών συνδυάζονται μέσω των μεταβλητών *timing_dependence* και *weight_dependence* σε ένα αντικείμενο *STDPMechanism*, το οποίο περιγράφει τον συνολικό επιθυμητό μηχανισμό. Σημειώνεται πως η προβολή, ακόμα, απαιτεί τον προσδιορισμό ενός συνδέτη. Ο συνδέτης σε αυτή την περίπτωση χρησιμοποιείται για την περιγραφή της συνολικής συνδεσιμότητας μεταξύ των νευρώνων των προσυναπτικών και μετασυναπτικών πληθυσμών. Είναι προτιμητέο οι τιμές των αρχικών βαρών να βρίσκονται μεταξύ *w_min* και *w_max*.

Αξίζει να σημειωθεί πως ενώ το πακέτο *sPyNNaker* υποστηρίζει τον ορισμό πολλαπλών προβολών στον ίδιο πληθυσμό στόχο μέσω του *STDP*, υπάρχει ο περιορισμός ότι όλες οι προβολές πρέπει να χρησιμοποιούν τους ίδιους κανόνες με ακριβώς τις ίδιες παραμέτρους. Αυτό οφείλεται στους περιορισμούς της τοπικής μνήμης που είναι διαθέσιμης για κάθε πυρήνα, μειώνοντας το πλήθος δεδομένων που μπορεί να αποθηκευτεί ως παράμετροι. Ακόμα, στην υλοποίηση του αλγορίθμου *STDP* στον *SpINNaker*, ο μηχανισμός πλαστικότητας ενεργοποιείται όταν λαμβάνεται η δεύτερη προσυναπτική αιχμή από τον μετασυναπτικό νευρώνα. Έτσι, απαιτούνται τουλάχιστον δύο προσυναπτικές αιχμές για την ενεργοποίηση του μηχανισμού.

Κεφάλαιο 4

Συγγενείς Εργασίες

"If I have seen further it is by standing on the shoulders of Giants."

— Issac Newton

Για να περιηγηθούμε στο μεγάλο και ταχέως αναπτυσσόμενο επιστημονικό πεδίο των Διεπαφών Εγκεφάλου-Υπολογιστή, είναι αναγκαίο να αναφερθούμε σε σχετικές εργασίες προηγούμενων ερευνητικών ομάδων. Σε αυτό το κεφάλαιο θα καλύψουμε πρώτα πρόσφατες εργασίες σε ΔΕΥ που βασίζονται σε δεδομένα ΗΕΓ και χρησιμοποιούν στατιστικούς και νευρομορφικούς ταξινομητές. Στο δεύτερο μέρος του κεφαλαίου θα παρουσιάσουμε διαφορετικές μεθόδους αποκωδικοποίησης και εξαγωγής χαρακτηριστικών για κινήσεις νοεράς απεικόνισης από δεδομένα ΗΕΓ. Στο τρίτο και τελευταίο μέρος περιγράφεται η αρχιτεκτονική ενός ΝΔΑ που βασίζεται στο οσφρητικό σύστημα εντόμων.

4.1 Διεπαφές Εγκεφάλου-Υπολογιστή με χρήση δεδομένων ΗΕΓ

Τα τελευταία 20 χρόνια έχουν σημειωθεί εντυπωσιακά επιτεύγματα στον κλάδο των Διεπαφών Εγκεφάλου-Υπολογιστή και συγκεκριμένα σε αυτές που βασίζονται σε νοητικές κινήσεις για ένα μεγάλο εύρος εφαρμογών. Παράλληλα, έχουν παρουσιαστεί και διερευνηθεί εκτενώς διάφορες προσεγγίσεις για την αποκωδικοποίηση σημάτων ΗΕΓ. Ωστόσο, η πλειοψηφία των σχετικών δημοσιεύσεων βασίζεται σε ΔΕΥ οι οποίες κάνουν χρήση στατιστικών αλγορίθμων μηχανικής μάθησης, όπως οι Μηχανές Διανυσμάτων Υποστήριξης (Support Vector Machines - SVM) [110, 98] και η Γραμμική Διακριτική Ανάλυση (Linear Discriminant Analysis - LDA) [98, 105, 26] για την αποκωδικοποίηση των δεδομένων. Για παράδειγμα, οι Yong et al. [110], οι οποίοι ασχολήθηκαν με την ταξινόμηση σημάτων ΗΕΓ νοητικών κινήσεων που προέρχονταν από το ίδιο άκρο, στην έρευνά τους, ταξινόμησαν σήματα που αντιστοιχούσαν σε τρεις κατηγορίες: κατάσταση ηρεμίας, νοητική κίνηση σύλληψης αντικειμένου και νοητική κίνηση του αγκώνα. Τα καλύτερα αποτελέσματα τα πέτυχαν χρησιμοποιώντας τον αλγόριθμο SVM και εκπαιδεύοντάς τον με τρόπο ασύγχρονο¹. Για την δυαδική ταξινόμηση των κινήσεων σύλληψης και των κινήσεων του αγκώνα, η μέση ορθότητα που επιτεύχθηκε ήταν 66.9%. Για το πρόβλημα της ταξινόμησης και των τριών κατηγοριών η μέση ορθότητα ταξινόμησης που επιτεύχθηκε ήταν 60.7%.

Με βάση την βιβλιογραφική επισκόπηση που έγινε στα πλαίσια της εργασίας, οι δημοσιεύσεις που εστιάζουν στην χρήση των Νευρωνικών Δικτύων Αιχμών σε ΔΕΥ είναι σημαντικά λιγότερες συγκριτικά με όσες χρησιμοποιούν πιο παραδοσιακές μεθόδους μηχανικής μάθησης [13, 51].

¹Σύγχρονη εκπαίδευση (online training) έχουμε όταν η μάθηση λαμβάνει χώρα καθώς έρχονται νέα δεδομένα, ενώ στην ασύγχρονη (offline training) γίνεται χρήση ενός στατικού σετ δεδομένων για την εκπαίδευση.

Οι Tayeb et al. [99] ανέπτυξαν ένα ΝΔΑ το οποίο βασίζεται στην αρχιτεκτονική του βιολογικού οσφρητικού συστήματος εντόμων (βλέπε Ενότητα 4.3) και στη συνέχεια το εφάρμοσαν στο πρόβλημα της ταξινόμησης νοητικών κινήσεων. Το δίκτυο που δημιούργησαν προσομοιώθηκε στην νευρομορφική υπολογιστική πλατφόρμα SpiNNaker (βλέπε Ενότητα 2.3.5). Για την επεξεργασία των σημάτων ΗΕΓ χρησιμοποιήθηκαν υποζώνες συχνοτήτων των άλφα και βήτα ζωνών (βλέπε Ενότητα 4.2). Οι τελικές αριθμητικές τιμές που εξήχθησαν από τα δεδομένα, τοποθετήθηκαν, έπειτα, στο δίκτυο υπό τη μορφή ακολουθιών αιχμών. Η διαδικασία της μάθησης, δηλαδή η βελτιστοποίηση των βαρών του ΝΔΑ έγινε χειροκίνητα, δεδομένου ότι δεν υλοποιήθηκε κάποιος αλγόριθμος μάθησης. Με βάση την παραπάνω διαδικασία πέτυχαν ορθότητα (ασύγχρονης) ταξινόμησης νοητικών κινήσεων του δεξιού και αριστερού χεριού 70% με τη χρήση του ΝΔΑ και 75% με τη χρήση του αλγορίθμου SVM.

Παρόμοια προσέγγιση ακολούθησαν και οι Lungu et al. [63], οι οποίοι χρησιμοποίησαν την ίδια αρχιτεκτονική δικτύου που βασίζεται στο οσφρητικό σύστημα εντόμων για την πρόβλεψη δύο αντιθέτων κατευθύνσεων κατά τη διάρκεια νοητικών κινήσεων. Σε σύγκριση με τη δουλειά των Tayeb et al. στην οποία αναφερθήκαμε παραπάνω, των δικτύων των Lungu et al. εκπαιδεύτηκε και ελέγχθηκε στο νευρομορφικό τσιπ Spikey [78], το οποίο αποτελεί μία νευρομορφική πλατφόρμα που χρησιμοποιεί αναλογικά στοιχεία για την προσομοίωση της συμπεριφοράς ενός νευρώνα. Το δίκτυο αυτό δεν απαιτούσε ενδιάμεση αναπαράσταση πραγματικών αριθμών, αφού τα καταγεγραμμένα δεδομένα ήταν υπό τη μορφή αιχμών. Ως αποτέλεσμα, όλοι οι υπολογισμοί εκτελέστηκαν στους νευρώνες αιχμών. Με αυτή την προσέγγιση, κατάφεραν να επιτύχουν ορθότητα ταξινόμησης 89.32% σε δεδομένα που το σύστημα δεν είχε ξαναδεί.

Σημειώνεται πως παραπάνω έγινε αναφορά μόνο σε αντιπροσωπευτικές εργασίες του αντίστοιχου ερευνητικού πεδίου που είχαν θετικά αποτελέσματα, οι οποίες κάνουν χρήση του μοντέλου ΝΔΑ που χρησιμοποιήθηκε στην εργασία και στις οποίες βασίστηκαν οι υλοποιημένοι μέθοδοι. Αξίζει, επίσης, να τονιστεί πως τα διαθέσιμα μοντέλα Νευρωνικών Δικτύων Αιχμών είναι σημαντικά λιγότερα σε σύγκριση με αυτά των παραδοσιακών Τεχνητών Νευρωνικών Δικτύων, εξαιτίας της στενής τους σχέσης με τις εξελίξεις στον κλάδο της Νευροεπιστήμης.

4.2 Μέθοδοι Αποκωδικοποίησης Νοητικών Κινήσεων από δεδομένα ΗΕΓ

Χαρακτηριστικά Ισχύος Ζώνης Συχνοτήτων

Μία από τις πιο δημοφιλείς και ευρέως χρησιμοποιούμενες μεθόδους εξαγωγής χαρακτηριστικών σε δεδομένα ΗΕΓ σχετίζεται με την εκμετάλλευση των ενεργειακών χαρακτηριστικών διαφόρων ζωνών συχνοτήτων. Για την εξαγωγή χαρακτηριστικών από τα διαθέσιμα δεδομένα, οι Tayeb et al. [99], υπολόγισαν την ισχύ της ζώνης συχνοτήτων των καταγεγραμμένων σημάτων ΗΕΓ. Για κάθε κανάλι, υπολογίστηκαν χαρακτηριστικά ισχύος σε 72 υποζώνες συχνοτήτων, στις ζώνες άλφα και βήτα, χρησιμοποιώντας διαφορετικά επικαλυπτόμενα μικρά παράθυρα μεταξύ των συχνοτήτων 8 και 25 Hz.

Ποσοτικοποίηση ERD/ERS

Όπως αναφέραμε στην Ενότητα 2.1.2, η μείωση ή η αύξηση της ισχύος του σήματος ΗΕΓ σχετίζεται με γεγονότα συγχρονισμού (Event-Related Synchronization - ERS) ή αποσυγχρονισμού (Event-Related Desynchronization - ERD) των νευρώνων. Μία εναλλακτική μέθοδος υπολογισμού των χαρακτηριστικών ΗΕΓ είναι η ποσοτικοποίηση των ERD/ERS κατά τη διάρκεια νοητικών κινήσεων. Η τεχνική αυτή βασίζεται στην υπόθεση ότι εάν μία ομάδα νευρώνων που συμμετέχουν στην ίδια νοητική εργασία αποσυγχρονιστούν ως προς τη συχνότητά τους, τότε η ισχύς σε αυτή

τη ζώνη συχνοτήτων μειώνεται. Όμοια, αν μια ομάδα νευρώνων συμμετέχει στην ίδια γνωστική εργασία, θα συγχρονιστούν για ένα σύντομο χρονικό διάστημα μέχρι να επιστρέψουν στους αρχικούς ρυθμούς ενεργοποίησής τους. Έτσι, η κίνηση ή η προετοιμασία για κίνηση σχετίζεται με μία μείωση της νευρικής δραστηριότητας στην ζώνη συχνοτήτων άλφα (ERD). Στην αντίθετη περίπτωση, η αύξηση του ρυθμού ενεργοποίησης (συγχρονισμός) συμβαίνει στην χρονική περίοδο που ακολουθεί μία κίνηση, στην οποία παρατηρείται μία χαλάρωση στη ζώνη συχνοτήτων βήτα. Τα ERD και ERS ποσοτικοποιούνται ως το ποσοστό μείωσης ή αύξησης της ισχύος του ΗΕΓ σε συγκεκριμένες ζώνες συχνοτήτων συγκριτικά με την κατάσταση αδράνειας πριν από την νοητική κίνηση [94], όπως φαίνεται στην Εξίσωση 4.1.

$$ERD\% = \frac{P_A - P_R}{P_R} \quad (4.1)$$

, όπου P_A είναι η ισχύς μεταξύ των συχνοτήτων ενδιαφέροντος, για παράδειγμα μέσα στη ζώνη άλφα, και P_R είναι η ισχύς αναφοράς κατά τη διάρκεια της κατάστασης αδράνειας. Οι Sivakami R et al. [94] στην εργασία τους, υπολόγισαν τα ERD και ERS ακολουθώντας τα παρακάτω βήματα:

1. Ζωνοπερατό φιλτράρισμα των καταγεγραμμένων σημάτων ΗΕΓ στις διαθέσιμες δοκιμές.
2. Τετραγωνισμός των δειγμάτων πλάτους για την απόκτηση δειγμάτων ισχύος.
3. Υπολογισμός του μέσου όρου των δειγμάτων ισχύος για όλες τις δοκιμές.
4. Υπολογισμός του μέσου όρου των δειγμάτων χρόνου για εξομάλυνση των δεδομένων και μείωση της μεταβλητότητας.

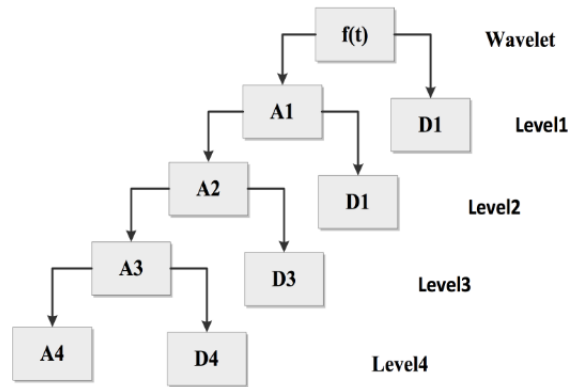
Με τη χρήση αυτών των χαρακτηριστικών ERD και ERS οι Sivakami et al. [94] πέτυχαν μέση ορθότητα ταξινόμησης κινήσεων του αριστερού και δεξιού χεριού 70.5%.

Διακριτός Μετασχηματισμός Κυματιδίων

Η δεύτερη μέθοδος που χρησιμοποίησαν οι Sivakami et al. στην έρευνά τους για εξαγωγή χαρακτηριστικών από τα διαθέσιμα δεδομένα, ήταν ο Διακριτός Μετασχηματισμός Κυματιδίων (Discrete Wavelet Transform - DWT) [94]. Ο μετασχηματισμός αυτός δίνει τη δυνατότητα ανάλυσης ενός σήματος το οποίο βρίσκεται τόσο στο πεδίο του χρόνου όσο και στο πεδίο της συχνότητας. Δεδομένου ότι τα σήματα ΗΕΓ είναι μη στάσιμα και παροδικά, η εξαγωγή χαρακτηριστικών από αυτά καθίσταται δύσκολη λαμβάνοντας υπόψη μόνο το πεδίο της συχνότητας μέσω παραδοσιακών μεθόδων ανάλυσης φάσματος. Για το λόγο αυτό, η ανάλυση κυματιδίων θα μπορούσε να συμβάλει σημαντικά στο υπό εξέταση πρόβλημα ταξινόμησης. Με βάση αυτή, το σήμα διαχωρίζεται σε ένα σετ από συναρτήσεις, οι οποίες προκύπτουν από μετατοπίσεις και διαστολές μίας συνάρτησης που αποτελεί το βασικό κυματίδιο. Αυτό σημαίνει ότι μπορεί να εξαχθεί τα συστατικά του σε διαφορετικές ζώνες συχνοτήτων, διατηρώντας παράλληλα τα χρονικά χαρακτηριστικά των σημάτων. Ο DWT ενός σήματος $f(t)$ δίνεται από την ακόλουθη εξίσωση:

$$C_{j,k}(f, \phi_{j,k}) = 2^{-j/2} \sum_{n=-\infty}^{\infty} f(t) \bar{\phi}(2^{-j}t - k), \text{ για } j, k \in Z \quad (4.2)$$

, όπου το $\phi_{j,k}(t) = 2^{-j/2} \phi(2^{-j}t - k)$ αποτελεί μία ακολουθία κυματιδίων, $\phi(t)$ είναι το βασικό κυματίδιο, ενώ τα j και k είναι η ανάλυση συχνότητας και χρόνου του μετασχηματισμού αντίστοιχα. Με χρήση του μετασχηματισμού κυματιδίων μπορούμε τελικά να λάβουμε ένα συστατικό (συντελεστή) προσέγγισης υψηλής κλίμακας και χαμηλής συχνότητας A (approximation) του σήματος $f(t)$ και ένα συστατικό λεπτομέρειας χαμηλής κλίμακας και υψηλής συχνότητας D (detail).



Σχήμα 4.1: Αποσύνθεση του σήματος $f(t)$ σε συνιστώσες με χρήση του DWT 4 επιπέδων [57].

Στο Σχήμα 4.1 φαίνεται ένα σχεδιάγραμμα που παρουσιάζει τα συστατικά μιας πολυεπίπεδης ανάλυσης σήματος με βάση τον DWT.


Για την αποσύνθεση των καταγεγραμμένων σημάτων ΗΕΓ μέσω του DWT, οι Sivakami et al. επέλεξαν να χρησιμοποιήσουν κυματίδια τύπου Daubechies 6 [94]. Το επίπεδο της αποσύνθεσης εξαρτάται κάθε φορά από τις συχνότητες ενδιαφέροντος και την συχνότητα δειγματοληψίας των αρχικών σημάτων του ηλεκτροεγκεφαλογραφήματος, η οποία στην περίπτωση τους ήταν 256 Hz. Ως αποτέλεσμα, επιλέχθηκε αποσύνθεση 5 επιπέδων και το σήμα ΗΕΓ διαχωρίστηκε στους συντελεστές λεπτομέρειας D1-D5 και στον συντελεστή προσέγγισης A5. Οι συντελεστές τύπου D5 αντιστοιχούν στην ζώνη συχνοτήτων άλφα, ενώ οι συντελεστές D4 στην (κεντρική) ζώνη βήτα. Τα τελικά εξαγόμενα χαρακτηριστικά που λήφθηκαν υπόψη είναι ο μέσος όρος της απόλυτης τιμής των συντελεστών κυματιδίων και η τυπική απόκλιση των σχετικών συντελεστών υποζώνης D4 και D5. Τα χαρακτηριστικά αυτά αναπαριστούν την κατανομή της συχνότητας, καθώς και το πλήθος αλλαγών της κατανομής αυτής. Έτσι, για κάθε κανάλι εξήχθησαν 4 χαρακτηριστικά, οι μέσοι όροι και οι τυπικές αποκλίσεις που αντιστοιχούν στις υποζώνες άλφα και βήτα. Χρησιμοποιώντας αυτά τα χαρακτηριστικά κατάφεραν να πετύχουν μέση ορθότητα ταξινόμησης κινήσεων του δεξιού και του αριστερού χεριού 72%.

Μία παρόμοια προσέγγιση που κάνει χρήση του μετασχηματισμού κυματιδίων για την εξαγωγή χαρακτηριστικών από σήματα ΗΕΓ που αντιστοιχούν σε νοητικές κινήσεις των χεριών παρουσιάστηκε από τους Li et al. [57], η οποία αποτελεί μία τροποποιημένη εκδοχή της παραπάνω προσέγγισης. Με βάση αυτή τη μέθοδο, ο αριθμός των συντελεστών προκύπτει από τον αριθμό επιπέδων του DWT: $A_L, D_L, D_{L-1}, \dots, 1$, όπου L ο βαθμός αποσύνθεσης του αρχικού σήματος. Τα καταγεγραμμένα σήματα ΗΕΓ που χρησιμοποίησαν ήταν δειγματοληπτημένα σε συχνότητα 128 Hz και διασπαστήκαν σε 6 επίπεδα με τη χρήση ενός κυματιδίου τύπου Daubechies 4-tap. Οι προκύπτουσες ζώνες συχνοτήτων είναι: $0Hz-1Hz, 1Hz-2Hz, 2Hz-4Hz, 4Hz-8Hz, 8Hz-16Hz, 16Hz-32Hz, 32Hz-64Hz$. Το διαχωρισμένο σήμα φαίνεται στο Σχήμα 4.2.

Από τις παραπάνω ζώνες συχνοτήτων, τα τελικά χαρακτηριστικά ΗΕΓ των νοητικών κινήσεων υπολογίζονται με βάση τον ακόλουθο τύπο:

$$F = C_3A_6 + C_4A_6C_ZA_6 \quad (4.3)$$

, όπου F είναι το διάνυσμα χαρακτηριστικών για τον διαχωρισμό μεταξύ των νοητικών κινήσεων των δύο χεριών, ενώ το γινόμενο C_iA_j αναπαριστά τους συντελεστές κυματιδίων A_j στο κανάλι C_i . Με βάση αυτά τα χαρακτηριστικά επετεύχθη ορθότητα ταξινόμησης 93.3% χρησιμοποιώντας ένα αναδρομικό νευρωνικό δίκτυο και 89% με τη χρήση του αλγορίθμου ταξινόμησης Naive Bayes.



Σχήμα 4.2: Αποσύνθεση σήματος ΗΕΓ σε συντελεστές με χρήση του DWT 6 επιπέδων [57].

4.3 Νευρωνικό Δίκτυο Αιχμών για την ταξινόμηση δεδομένων ΗΕΓ

Η αρχιτεκτονική του νευρωνικού δικτύου αιχμών που χρησιμοποιείται σε αυτή την εργασία και σε άλλες που αναφέραμε στην προηγούμενη ενότητα [99, 63] βασίζεται στο οσφρητικό σύστημα εντόμων όπως αυτό προτάθηκε από τους Schmuker et al. [91]. Στην έρευνά τους, παρουσίασαν ένα Νευρωνικό Δίκτυο Αιχμών για ταξινόμηση με επίβλεψη πολυμεταβλητών δεδομένων, ενώ έδειξαν πως ο ταξινομητής τους υποστηρίζει μη γραμμικό διαχωρισμό κλάσεων.

Το δίκτυο ταξινόμησης που ανέπτυξαν σχεδιάστηκε με τρόπο ώστε να προσεγγίζει τις βασικές αρχές του οσφρητικού συστήματος των εντόμων. Μετά από πολλά χρόνια εξέλιξης, το αισθητηριακό σύστημα των εντόμων έχει προσαρμοστεί κατάλληλα ώστε να μπορεί να κωδικοποιεί και να ταξινομεί χημικές οσμές αποδοτικά. Έτσι, τα νευρωνικά δίκτυα που απαρτίζουν το οσφρητικό τους σύστημα φαίνεται να υλοποιούν μία αποδοτική μέθοδο για κωδικοποίηση, επεξεργασία και ταξινόμηση της πληροφορίας. Πιο συγκεκριμένα, το οσφρητικό σύστημα είναι υπεύθυνο για την μετάφραση της χημικής πληροφορίας σε νευρωνικά σήματα, τα οποία υφίστανται επεξεργασία καθώς μεταδίδονται σε κέντρα υψηλότερων λειτουργιών του εγκεφάλου [91]. Η ομάδα των Schmuker et al. για να εξετάσει κατά πόσο οι αρχές επεξεργασίας της πληροφορίας που διέπουν τα υπό μελέτη οσφρητικά συστήματα μπορούν να εφαρμοστούν γενικότερα σε προβλήματα επεξεργασίας της πληροφορίας, σχεδίασαν ένα απλοποιημένο υπολογιστικό μοντέλο, το οποίο περιγράφει ουσιαστικά τα τρία βασικά στάδια επεξεργασίας των οσφρητικού συστήματος των εντόμων. Η αρχιτεκτονική αποτελείται από το επίπεδο εισόδου (input layer), το επίπεδο αποσυσχέτισης (decorrelation layer) και το επίπεδο συσχέτισης (association layer). Η λειτουργία των τριών επιπέδων περιγράφεται αναλυτικά ακολούθως, ενώ παρέχεται και μία σχεδιαστική περιγραφή στο Σχήμα 4.3-A.

Στο επίπεδο εισόδου δεδομένα πολλών διαστάσεων με πραγματικές τιμές μετασχηματίζονται σε θετικές ακολουθίες αιχμών πεπερασμένου πλάτους. Τα δεδομένα εισέρχονται στο δίκτυο μέσω ενός συνόλου από υποδοχείς νευρώνων (Receptor Neurons - RNs). Οι υποδοχείς αυτοί πυροδο-

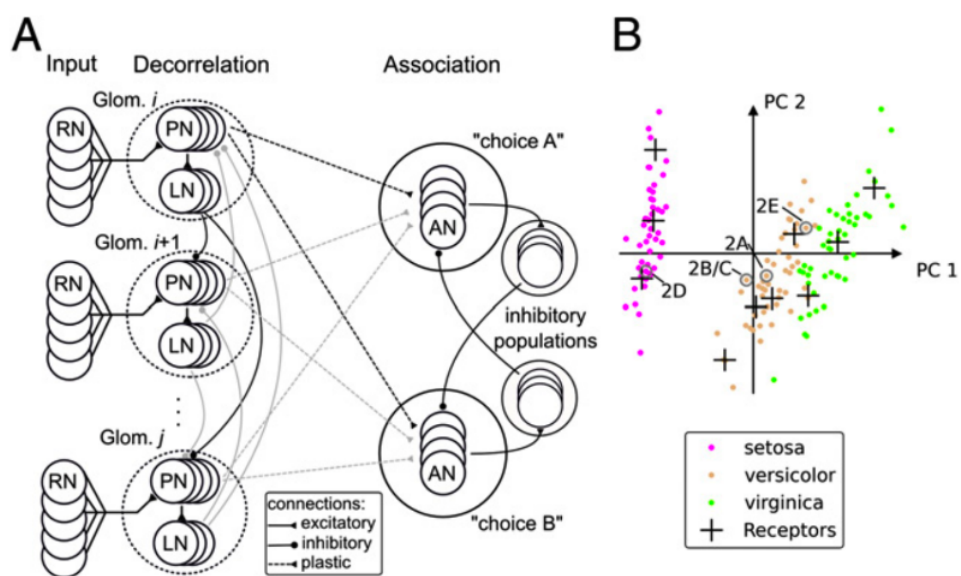
τούν ακολουθίες αιχμών σε συγκεκριμένους ρυθμούς, οι οποίοι υπολογίζονται από τα δεδομένα εισόδου πραγματικών τιμών με τη χρήση εικονικών υποδοχέων (Virtual Receptors - VRs). Ένας εικονικός υποδοχέας αντιστοιχεί στο κέντρο μίας γραμμικής συνάρτησης ακτινικής βάσης (Radial Basis Function - RBF) στον χώρο που ορίζουν τα εξαγόμενα χαρακτηριστικά των δεδομένων. Το μέγεθος της απόκρισής του σε ένα σημείο των δεδομένων εξαρτάται από την απόσταση μεταξύ του εικονικού υποδοχέα και του ερεθίσματος. Ως εκ τούτου, η απόκριση του εικονικού υποδοχέα είναι μεγάλη για μικρές αποστάσεις μεταξύ του υποδοχέα και του ερεθίσματος και το αντίστροφο. Οι εικονικοί υποδοχείς τοποθετούνται στον χώρο που ορίζουν τα δεδομένα με οργανωμένο τρόπο, χρησιμοποιώντας τον αλγόριθμο Neural Gas [65], όπως φαίνεται στο Σχήμα 4.3-B για το σετ δεδομένων Iris² που παρέχεται από το UCL.

Στο επίπεδο αποσυσχέτισης, σύνολα από υποδοχείς νευρώνων συνδέονται με ειδικούς νευρώνες προβολής (projection neurons - PNs), οι οποίοι είναι ομαδοποιημένοι σε σύνολα που αναπαριστούν τα επονομαζόμενα σπειράματα (glomeruli) στους κεραϊκούς λοβούς (antennal lobes) των εντόμων. Κάθε σύνολο από υποδοχείς νευρώνων στοχεύει ένα σπείραμα, το οποίο και λαμβάνει διεγερτική (ως προς το δυναμικό) είσοδο που αναπαριστά την ενεργοποίηση ενός εικονικού υποδοχέα. Οι νευρώνες προβολής συνδέονται με τοπικούς ανασταλτικούς (ως προς το δυναμικό) νευρώνες (Local Neurons - LNs), οι οποίοι με τη σειρά τους αναστέλλουν άλλα σπειράματα.

Η έξοδος του επιπέδου αποσυσχέτισης προβάλλεται στο επίπεδο συσχέτισης, στο οποίο πραγματοποιείται μάθηση με επίβλεψη για την ταξινόμηση των δεδομένων. Εκεί, νευρώνες συσχέτισης (association neurons - ANs) ομαδοποιούνται σε τόσους πληθυσμούς όσες και οι κατηγορίες του σετ δεδομένων. Σε κάθε τέτοιο πληθυσμό στο επίπεδο συσχέτισης ανατίθεται μία ετικέτα μιας κλάσης του σετ δεδομένων. Οι ομάδες των νευρώνων συσχέτισης με τη σειρά τους συνδέονται με συσχετιζόμενους πληθυσμούς ανασταλτικών νευρώνων. Η ισχυρή ανασταλτική συμπεριφορά που επικρατεί μεταξύ των πληθυσμών των νευρώνων συσχέτισης προκαλεί το φαινόμενο της επικράτησης του πληθυσμού που μοιάζει περισσότερο με τη είσοδο (winner take all). Τα συναπτικά βάρη που συνδέουν τους νευρώνες προβολής με τους νευρώνες συσχέτισης αρχικοποιούνται τυχαία. Έτσι, ένα μοτίβο δραστηριότητας που παρουσιάζεται στο δίκτυο, μπορεί κατά τύχη να μεταφέρει πολύ περισσότερη είσοδο στον ένα πληθυσμό σε σύγκριση με τον άλλο, το οποίο θα έχει ως αποτέλεσμα υψηλότερους ρυθμούς ενεργοποίησης των νευρώνων του πληθυσμού που επιλέχθηκε. Εάν η ετικέτα του πληθυσμού που επικράτησε ταιριάζει με αυτή του ερεθίσματος, το δίκτυο εκτέλεσε μία επιτυχημένη ταξινόμηση. Το δίκτυο εκπαιδεύεται με τρόπο ασύγχρονο και με επίβλεψη, τροφοδοτώντας το με ερεθίσματα των οποίων οι ετικέτες κλάσεων είναι γνωστές. Στην περίπτωση που η ταξινόμηση ήταν σωστή, οι ενεργές συνάψεις που ενώνουν τους νευρώνες προβολής με τον “νικητήριο” πληθυσμό του επιπέδου συσχέτισης, ενισχύονται. Στην περίπτωση που η ταξινόμηση ήταν λανθασμένη, οι ενεργές συνάψεις αποδυναμώνονται [91].

Για τον έλεγχο της απόδοσης ταξινόμησης της παραπάνω αρχιτεκτονικής οι Schmucker et al. [91] χρησιμοποίησαν διαφορετικά σετ δεδομένων. Πρώτα, το δίκτυο απέδειξε την ικανότητά του στην ταξινόμηση μη γραμμικών δεδομένων σε ένα δισδιάστατο σετ δεδομένων που αποτελούνταν από δύο κλάσεις. Οι κατηγορίες που προβλήματος είχαν τη μορφή ενός δαχτυλιδιού, δηλαδή η πρώτη βρισκόταν σε μία συστάδα στο κέντρο της αρχή των αξόνων, ενώ η δεύτερη γύρω από αυτό. Το δίκτυο ταξινόμησης εκτελέστηκε στο νευρομορφικό τσιπ Spikekey [78] και πέτυχε μέσο ρυθμό ταξινόμησης 96% στο παραπάνω σετ δεδομένων. Η χρήση του ταξινομητή Naive Bayes απέφερε παρόμοια αποτελέσματα, με μέση ορθότητα ταξινόμησης 98%. Με στόχο την περαιτέρω διερεύνηση των δυνατοτήτων της αρχιτεκτονικής, χρησιμοποιήθηκε, ακόμα, ένα υποσύνολο του σετ δεδομένων MNIST, αποτελούμενο από τα ψηφία 5 και 7 υπό τη μορφή εικόνων των 28 × 28 pixels. Στα δεδομένα αυτά, το υπό μελέτη Νευρωνικό Δίκτυο Αιχμών έφτασε ορθότητα 94%, ξεπερνώντας τον ταξινομητή Naive Bayes, ο οποίος πέτυχε ορθότητα 82%.

²<https://archive.ics.uci.edu/ml/datasets/iris>



Σχήμα 4.3: (A) Η αρχιτεκτονική 3 επιπέδων του Νευρωνικού Δικτύου Αιχμών των Schmuker et al. (B) Τοποθέτηση των εικονικών υποδοχέων στο σετ δεδομένων Iris του UCL [91].

Κεφάλαιο 5

Αρχιτεκτονική

“Computers are incredibly fast, accurate and stupid; humans are incredibly slow, inaccurate and brilliant; together they are powerful beyond imagination.”

— Albert Einstein

Σε αυτό το Κεφάλαιο θα γίνει αρχικά μία επισκόπηση της αρχιτεκτονικής που χρησιμοποιήθηκε για την εξαγωγή χαρακτηριστικών από τα διαθέσιμα δεδομένα, καθώς και για την ταξινόμηση αυτών σε κλάσεις με τη χρήση ενός Νευρωνικού Δικτύου Αιχμών. Στο δεύτερο μέρος του Κεφαλαίου περιγράφονται τα πειραματικά δεδομένα που χρησιμοποιήθηκαν για τον έλεγχο και την αξιολόγηση της παραπάνω υλοποίησης.

5.1 Εξαγωγή και Ταξινόμηση Χαρακτηριστικών ΗΕΓ

Ο στόχος αυτής της εργασίας είναι η υλοποίηση και αναπαραγωγή της προσέγγισης των Zied Tayeb et al. [99] για την ταξινόμηση νοητικών κινήσεων που προέρχονται από δεδομένα ΗΕΓ δύο κλάσεων με τη χρήση ενός Νευρωνικού Δικτύου Αιχμών, ενώ ιδιαίτερη έμφαση δίνεται και στην σύγκριση μεταξύ της απόδοσης ενός ΝΔΑ και ενός στατιστικού ταξινομητή στα διαθέσιμα δεδομένα. Το δίκτυο που χρησιμοποιήθηκε βασίζεται στο οσφρητικό σύστημα των εντόμων, όπως αυτό παρουσιάστηκε στην Ενότητα 4.3, και υλοποιήθηκε στην νευρομορφική υπολογιστική πλατφόρμα SpINNAker, η οποία περιγράφηκε στην Ενότητα 2.3.5.

Για την βελτίωση της απόδοσης του δικτύου, η χειροκίνητη ρύθμιση των βαρών μεταξύ των δύο τελευταίων επιπέδων του ΝΔΑ, αντικαταστάθηκε από έναν αλγόριθμο μάθησης ανταμοιβής τύπου STDP (βλέπε Ενότητα 2.3.4). Επιπρόσθετα, εφαρμόστηκε βελτιστοποίηση των παραμέτρων του δικτύου, σε συνδυασμό με μαζική μάθηση (batch learning) στα κωδικοποιημένα χαρακτηριστικά, ενώ δοκιμάστηκε και ο αλγόριθμος της Ομοιόστασης [82] για την εκπαίδευση του δικτύου, του οποίου η λειτουργία θα αναλυθεί στο επόμενο Κεφάλαιο.

Γνωρίζοντας ότι η ακρίβεια ταξινόμησης ενός Νευρωνικού Δικτύου, εξαρτάται σε έναν μεγάλο βαθμό από την ποιότητα των χαρακτηριστικών που χρησιμοποιούνται για την εκπαίδευσή του, δοκιμάστηκαν διαφορετικές μέθοδοι εξαγωγής χαρακτηριστικών, όπως αυτές παρουσιάστηκαν στην Ενότητα 4.2. Πιο συγκεκριμένα, οι τεχνικές που χρησιμοποιήθηκαν για τον υπολογισμό των χαρακτηριστικών είναι:

- Ισχύς ζώνης συχνοτήτων
- Λογαριθμική ισχύς ζώνης συχνοτήτων
- Ποσοτικοποίηση ERD/ERS

- Διακριτός Μετασχηματισμός Κυματιδίων

Τα τελικά χαρακτηριστικά χρησιμοποιούνται για την τροφοδότηση τόσο του υλοποιημένου ΝΔΑ όσο και παραδοσιακών στατιστικών ταξινομητών. Έτσι, καθίσταται δυνατή η αξιολόγηση τους ως προς την ικανότητά τους να συγκεντρώνουν ουσιώδη πληροφορία σχετική με τις νοητικές κινήσεις από δεδομένα ΗΕΓ.

5.2 Πειραματικά Δεδομένα

Έγινε προσπάθεια να χρησιμοποιηθούν τα ίδια σετ δεδομένων που αναφέρονται στην βιβλιογραφία, με στόχο την καλύτερη σύγκριση των αποτελεσμάτων. Τα πειραματικά δεδομένα που συλλέξαμε, δημοσιεύτηκαν πρώτη φορά από το Πανεπιστήμιο του Γκρατς της Αυστρίας στα πλαίσια του διεθνούς διαγωνισμού για Διεπαφές Εγκεφάλου-Υπολογιστή BCI Competition¹. Συνολικά έχουν διεξαχθεί τέσσερις τέτοιοι διαγωνισμοί, το 2001, 2003, 2005 και 2008. Σε αυτή την εργασία έγινε χρήση δημοσιευμένων δεδομένων από τους διαγωνισμούς των ετών 2003 και 2008, τα οποία αποτελούνται από καταγραφές ΗΕΓ που αναπαριστούν νοητικές κινήσεις. Σημειώνεται πως όλες οι καταγραφές χαρακτηρίζονται από κοινή χρονολογία γεγονότων, όπως αυτή φαίνεται στο Σχήμα 2.8, ενώ διαφέρουν μεταξύ τους ως προς τις δράσεις του υποκειμένου (νοητικές κινήσεις των άκρων), καθώς και τα χρονικά πλαίσια ανάλογα με τον τύπο της συνεδρίας.

BCI Competition 2003

Το ένα από τα δύο σετ πειραμάτων που χρησιμοποιήθηκαν σε αυτή την εργασία είναι το τρίτο σύνολο δεδομένων που δημοσιεύτηκε στα πλαίσια του BCI Competition 2003 από το Πανεπιστήμιο του Γκρατς [8]. Περιλαμβάνει 140 δοκιμές για την εκπαίδευση και τον έλεγχο ενός ταξινομητή. Η διαδικασία απόκτησης πειραματικών δεδομένων που χρησιμοποιήσαν φαίνεται στο Σχήμα 5.1. Η καταγραφή σημάτων ΗΕΓ κατά τη διάρκεια μίας συνεδρίας γίνεται κάθε 9 δευτερόλεπτα, με διαστήματα 2 λεπτών μεταξύ των πειραμάτων. Τα 2 πρώτα δευτερόλεπτα υπάρχει ηρεμία, σε χρόνο $t = 2s$ ένα ακουστικό ερέθισμα σηματοδοτεί την έναρξη της δοκιμής και ένας σταυρός "+" προβάλλεται για 1s. Σε χρόνο $t = 3s$, προβάλλεται ένα βέλος που δείχνει προς τα αριστερά ή προς τα δεξιά ως σύνθημα. Την ίδια στιγμή ζητείται από το υποκείμενο να μετακινήσει μία μπάρα που βρίσκεται μπροστά του στην κατεύθυνση που υποδεικνύει το βέλος, με το να σκεφτεί την κίνηση του κατάλληλου χεριού του. Κάθε καταγραφή εκτελέστηκε κάνοντας χρήση ενός ενισχυτή G.tec² και ηλεκτροδίων τύπου Ag/AgCl³. Μετρήθηκαν τρία διπολικά κανάλια ΗΕΓ από τα ηλεκτρόδια C3, C4 και Cz, ενώ έγινε δειγματοληψία των δεδομένων στα 128Hz.


BCI Competition 2008

Το νεότερο δημοσιευμένο σύνολο δεδομένων ΗΕΓ που χρησιμοποιήθηκε στα πλαίσια αυτής της εργασίας είναι το δεύτερο σετ πειραμάτων του BCI Competition 2008, που αναρτήθηκε από το Πανεπιστήμιο του Γκρατς [55]. Σε αυτό, αποκτήθηκαν σήματα ΗΕΓ από τρεις διπολικές καταγραφές των ηλεκτροδίων C3, C4 και Cz, τα οποία υπέστησαν δειγματοληψία 250Hz. Η κάθε συνεδρία αποτελείται από δοκιμές, στις οποίες ένα οπτικό σύνθημα, υποδεικνύει στα υποκείμενα για ποιο χέρι να φανταστούν την κίνησή του (βλέπε Σχήμα 5.2). Οι κλάσεις είναι δύο; κίνηση του δεξιού χεριού, κίνηση του αριστερού χεριού. Κάθε δοκιμή, ξεκινάει με την προβολή ενός σταυρού "+", ενώ σε χρόνο $t = 2s$ ακούγεται ένας σύντομος προειδοποιητικός ηχητικός τόνος. Σε χρόνο


¹<http://www.bbci.de/competition/>

²<https://tmesystems.net/portfolio/g-tec/>

³<https://www.biopac.com/product/ag-agcl-electrodes/>



Σχήμα 5.1: Καταγραφή σημάτων ΗΕΓ από το Πανεπιστήμιο του Γκρας στα πλαίσια του BCI Competition 2003 [8]. Θέσεις ηλεκτροδίων (αριστερά). Χρονοδιάγραμμα δοκιμών (δεξιά).



Σχήμα 5.2: Καταγραφή σημάτων ΗΕΓ από το Πανεπιστήμιο του Γκρας στα πλαίσια του BCI Competition 2008 [55]. Χρονοδιάγραμμα δοκιμών.

$t = 3s$ το οπτικό σύνθημα εμφανίζεται για $1.25s$. Για τα επόμενα $4s$, τα υποκείμενα πρέπει να εκτελέσουν την κατάλληλη νοητική κίνηση. Την κάθε δοκιμή ακολουθεί ένα σύντομο διάλλειμα $1.5s$. Ακόμα, ένας τυχαίος κάθε φορά χρόνος το πολύ ενός δευτερολέπτου προστίθεται σε κάθε διάλλειμα. Συνολικά, 9 σετ δεδομένων, το καθένα αποτελούμενο από 120 δοκιμές, προέκυψαν από τις συνεδρίες.

Κεφάλαιο 6

Πειραματική Διαδικασία και Αποτελέσματα

“Technology, like art, is a soaring exercise of the human imagination.”

— Daniel Bell

6.1 Προεπεξεργασία δεδομένων

Πριν από την εξαγωγή χαρακτηριστικών, τα καταγεγραμμένα σήματα ΗΕΓ πρέπει να υποστούν κατάλληλη προεπεξεργασία, με στόχο την καταστολή ανεπιθύμητων αλλοιώσεων, καθώς και την ενίσχυση των πιο σημαντικών χαρακτηριστικών για περαιτέρω επεξεργασία. Όλα τα δεδομένα που συλλέχθηκαν είναι αποθηκευμένα στο General Data Format (GDF) για βιοϊατρικά σήματα [89], με ένα αρχείο για κάθε υποκείμενο και συνεδρία. Οι τρεις πρώτες συνεδρίες για κάθε υποκείμενο περιλαμβάνουν τις ετικέτες των κλάσεων για όλες τις δοκιμές και συνεπώς συμμετέχουν στην εκπαίδευση του δικτύου, ενώ οι υπόλοιπες δύο συνεδρίες χρησιμοποιούνται για τον έλεγχο του ταξινομητή και άρα την αξιολόγηση της απόδοσής του. Τα αρχεία GDF επεξεργάστηκαν με τη χρήση της εργαλειοθήκης ανοιχτού κώδικα BioSig και έγινε μετατροπή τους σε αρχεία τύπου MAT με τη χρήση του λογισμικού MATLAB. Τα υπόλοιπα βήματα προεπεξεργασίας υλοποιήθηκαν κάνοντας χρήση των βιβλιοθηκών NumPy και SciPy.Signal της γλώσσας Python (βλέπε Κεφάλαιο 3).

Ζωνοπερατό Φιλτράρισμα

Πρώτα, τα σήματα ΗΕΓ υπέστησαν φιλτράρισμα με τη χρήση ενός ψηφιακού ζωνοπερατού φίλτρου τύπου Butterworth τάξης 5 με εύρος $0.5 - 30\text{Hz}$. Ο λόγος που χρησιμοποιούμε χαμηλές συχνότητες είναι πως τα τμήματα των σημάτων που περιέχουν ουσιώδη πληροφορία σχετικά με τις νοητικές κινήσεις βρίσκονται σε χαμηλότερες ζώνες συχνοτήτων, αναφορικά, στις ζώνες άλφα και βήτα.

Ζωνοφρακτικό Φιλτράρισμα

Δεδομένου ότι η επίδραση του φιλτραρίσματος στα σήματα είναι ζυγισμένη, μεγαλύτερη δηλαδή στο κέντρο των τιμών του φίλτρου, δεν εξουδετερώνονται όλες οι παρεμβολές της ζώνης των 50Hz . Έτσι, κρίνεται αναγκαίο να εφαρμοστεί ζωνοφρακτικό φιλτράρισμα των σημάτων αμέσως μετά το ζωνοπερατό φιλτράρισμα. Χρησιμοποιείται ένα φίλτρο φραγμού ζώνης με στενή ζώνη

απόρριψης και υψηλό παράγοντα ποιότητας $Q = 30$ με σκοπό την εξασθένιση των συχνοτήτων κοντά στα 50Hz .

Κανονικοποίηση

Μετά το φιλτράρισμα, προχωράμε στην κανονικοποίηση των σημάτων ΗΕΓ. Για κάθε δοκιμή και ηλεκτρόδιο i , ο μέσος όρος \bar{x}_i του σήματος αφαιρείται από κάθε χρονικό δείγμα $x_i(t)$. Το αποτέλεσμα της προηγούμενης πράξης διαιρείται με την τυπική απόκλιση $SD(x)_i$, όπως φαίνεται από την Εξίσωση 6.1 παρακάτω.

$$x_i^*(t) = \frac{x_i(t) - \bar{x}_i}{SD(x)_i} \quad (6.1)$$

6.2 Εξαγωγή Χαρακτηριστικών

Για να καταφέρουμε να ταξινομήσουμε τα χωρικά και χρονικά μοτίβα που χαρακτηρίζουν τα διαθέσιμα σήματα ΗΕΓ, είναι αναγκαίο να εξαχθούν ουσιώδη χαρακτηριστικά από αυτά, προτού εφαρμοστούν οι αλγόριθμοι ταξινόμησης. Αρχικά, θα αναλύσουμε τον υπολογισμό των χαρακτηριστικών της ζώνης ισχύος. Έπειτα, θα γίνει περιγραφή της μεθοδολογίας υπολογισμού των χαρακτηριστικών ERD και ERS. Στο τελευταίο μέρος αυτής της Ενότητας γίνεται αναφορά στην χρήση του Διακριτού Μετασχηματισμού Κυματιδίων στην εξαγωγή χαρακτηριστικών ΗΕΓ. Σημειώνεται πως όλα τα βήματα των μεθόδων υλοποιήθηκαν με τη χρήση των βιβλιοθηκών NumPy και SciPy.Signal της γλώσσας Python.

6.2.1 Γεγονότα Συγχρονισμού και Αποσυγχρονισμού

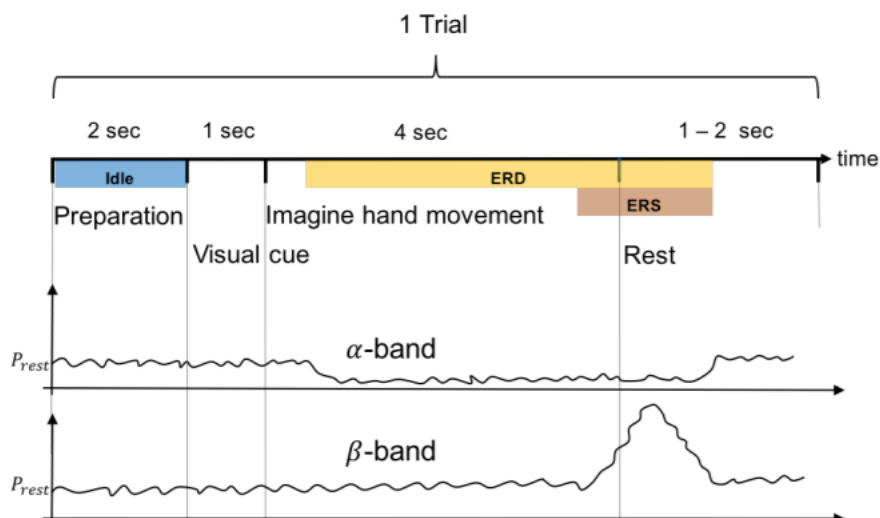
Όπως αναφέραμε στην Ενότητα 4.2, οι νοητικές κινήσεις ενός υποκειμένου προκαλούν αύξηση ή μείωση στην ισχύ των σημάτων ΗΕΓ που καταγράφονται, εξαιτίας του συγχρονισμού (ή αποσυγχρονισμού) ομάδων από νευρώνες. Η αλλαγή αυτή συμβαίνει κυρίως στις ζώνες συχνοτήτων άλφα και βήτα σε σχέση με μία χρονική περίοδο αναφοράς κατά τη διάρκεια της κατάστασης ηρεμίας.

Χαρακτηριστικά Ισχύος Ζώνης Συχνοτήτων

Για τον υπολογισμό των χαρακτηριστικών ισχύος ζώνης για κάθε ένα από τα τρία κανάλια που περιέχουν χρήσιμη πληροφορία $C3$, $C4$, Cz , τα τμήματα του σήματος που αντιστοιχούν στην κατάσταση ηρεμίας και στις νοητικές κινήσεις, περικόπτονται με βάση τους χρόνους που φαίνονται στο Σχήμα 2.8. Στα σήματα που προέκυψαν μετά την περικοπή, εφαρμόζουμε ζωνοπερατό φιλτράρισμα σε 72 ζώνες συχνοτήτων χρησιμοποιώντας διαφορετικές επικαλυπτόμενες στενές ζώνες μεταξύ 8Hz και 30Hz . Τα χαρακτηριστικά υπολογίζονται, αφαιρώντας τις 216 τιμές ισχύος των τμημάτων ηρεμίας από τις τιμές ισχύος των τμημάτων που αντιστοιχούν σε νοητικές κινήσεις.

Ποσοτικοποίηση ERD/ERS

Για τον υπολογισμό των χαρακτηριστικών ERD/ERS ακολουθούμε την μεθοδολογία που αναλύσαμε στην Ενότητα 4.2. Αρχικά, κάθε κανάλι από τα $C3$, $C4$, Cz του σήματος περικόπτεται με στόχο να απομονώσουμε το τμήμα της κατάστασης ηρεμίας και τις χρονικές περιόδους των ERS/ERD. Τα χρονικά αυτά παράθυρα φαίνονται στο Σχήμα 6.1. Έπειτα, εφαρμόζουμε στο παράθυρο ηρεμίας ζωνοπερατό φιλτράρισμα με τη χρήση ενός ψηφιακού φίλτρου Butterworth τάξης 5



Σχήμα 6.1: Χρονικά παράθυρα των ERS/ERD στις ζώνες άλφα και βήτα [55].

στις συχνότητες $8 - 12Hz$ και $13 - 25Hz$, δεδομένου ότι η ισχύς κατά τη διάρκεια της κατάστασης ηρεμίας χρησιμεύει ως σημείο αναφοράς και στις δύο ζώνες συχνοτήτων. Τα τμήματα ERS και ERD φιλτράρονται και αυτά με το ίδιο φίλτρο Butterworth στις συχνότητες $8 - 12Hz$ και $13 - 30Hz$, αντίστοιχα. Από τα τμήματα του αρχικού σήματος που έχουν υποστεί περικοπή και φιλτράρισμα λαμβάνουμε τα δείγματα ισχύος τετραγωνίζοντας τα διαθέσιμα δείγματα πλάτους. Για τον υπολογισμό των τελικών χαρακτηριστικών, αφαιρούμε την μέση ισχύς μιας δοκιμής κατά τη διάρκεια των παραθύρων ERD από τα φιλτραρισμένα στην άλφα ζώνη χρονικά διαστήματα ηρεμίας. Όμοια, ο μέσος όρος των δειγμάτων ισχύος μιας δοκιμής κατά τη διάρκεια των παραθύρων ERS αφαιρείται από τα φιλτραρισμένα στη βήτα ζώνη χρονικά διαστήματα ηρεμίας.

Χαρακτηριστικά Λογαριθμικής Ισχύος Ζώνης Συχνοτήτων

Μία εναλλακτική μέθοδος είναι η εκτίμηση των μοτίβων ERS και ERD μέσω του λογάριθμου της διακύμανσης ενός σήματος HEΓ που έχει υποστεί ζωνοπερατό φιλτράρισμα σε συγκεκριμένα χρονικά διαστήματα. Ο λογάριθμος εφαρμόζεται με σκοπό η κατανομή των χαρακτηριστικών να γίνει προσεγγιστικά κανονική και συνεπώς καλύτερα ταξινομήσιμη για γραμμικούς αλγορίθμους. Η μεθοδολογία που θα αναλύσουμε παρακάτω βασίζεται στην δουλειά των Yuan Yang et al. [109].

Η διακύμανση των τμημάτων HEΓ στο πεδίο του χρόνου για κάθε δοκιμή i και κάθε κανάλι c υπολογίζεται ως εξής:

$$u_c(i) = \frac{2}{\tau - 1} \sum_{j=t_n}^{k_n + \tau - 1} (x_j - \bar{x}_i)^2 \quad (6.2)$$

, όπου X_{ij} το j -οστό δείγμα στο χρονικό διάστημα $\tau_n = [t_n, t_n + T - 1]$ της i -οστής δοκιμής των δεδομένων HEΓ w_m που έχουν υποστεί ζωνοπερατό φιλτράρισμα. Συμβολίζουμε με \bar{u}_i τη μέση τιμή όλων των δειγμάτων των φιλτραρισμένων δεδομένων HEΓ στο χρονικό διάστημα τ_n της i -οστής δοκιμής. Για κάθε κανάλι, το χαρακτηριστικό της λογαριθμικής ισχύος ζώνης ορίζεται από τον ακόλουθο τύπο:

$$BP_c(i) = \log(u_c(i)) \quad (6.3)$$

Με βάση τον παραπάνω ορισμό, η συνολική ισχύς ζώνης \widetilde{BP}_c^X , για κάθε κλάση και κάθε κανάλι

Πίνακας 6.1: Διαφορές μοτίβων (PDs) για τα τρία πρώτα υποκείμενα των δεδομένων του 2008.

Εύρος Συχνοτήτων	PD_{C3}	PD_{C4}	ΔPD
<i>Υποκείμενο 1, Δεδομένα 2008</i>			
8 – 10Hz	-0.0144	-0.0202	0.0061
9 – 11Hz	-0.0017	-0.0323	0.0305
10 – 12Hz	-0.0061	-0.0058	-0.0004
<i>Υποκείμενο 2, Δεδομένα 2008</i>			
8 – 10Hz	-0.0983	-0.072	-0.0275
9 – 11Hz	-0.1334	-0.1071	-0.0258
10 – 12Hz	-0.2583	-0.3696	0.1114
<i>Υποκείμενο 3, Δεδομένα 2008</i>			
8 – 10Hz	0.0006	0.0012	-0.0005
9 – 11Hz	0.0023	-0.0007	0.0034
10 – 12Hz	0.0072	0.0062	0.0003

υπολογίζεται παίρνοντας τον διάμεσο του μέσου όρου των διακυμάνσεων των δεδομένων για όλες τις δοκιμές. Κάνουμε χρήση του διαμέσου, καθώς είναι πιο εύρωστος στις ακραίες τιμές. Η συνολική ισχύς ζώνης γράφεται ως εξής:

$$\widetilde{BP}_c^X = \log(\tilde{u}_e) \quad (6.4)$$

, όπου \tilde{u}_e ο διάμεσος των διακυμάνσεων $u_c(i)$ για όλες τις δοκιμές μίας κλάσης.

Μπορούμε τώρα να ορίσουμε την διαφορά μοτίβων (Pattern Difference - PD) PD_c για τα κανάλια $C3$ και $C4$ μεταξύ των δύο κλάσεων του προβλήματος L (αριστερά) και R (δεξιά):

$$PD_{C3} = \widetilde{BP}_{C3}^L - \widetilde{BP}_{C3}^R \quad (6.5)$$

$$PD_{C4} = \widetilde{BP}_{C4}^L - \widetilde{BP}_{C4}^R \quad (6.6)$$

Όταν η διαφορά μοτίβων PD υπολογίζεται σε μικρές άλφα υποζώνες ενός σετ δεδομένων, τα αποτελέσματα δείχνουν σε ποιές ζώνες συχνοτήτων η μείωση της ισχύος ζώνης εξαιτίας των νοητικών κινήσεων είναι πιο εμφανής. Δεδομένου ότι η συγκεκριμένη ζώνη διαφέρει μεταξύ των υποκειμένων αλλά και των συνεδριών καταγραφής, τα αποτελέσματα θα διαφέρουν ανάλογα κατά μήκος της ζώνης άλφα.

Οι τιμές των PD_{C3} , PD_{C4} και $\Delta PD = PD_{C3} - PD_{C4}$ για τα τρία πρώτα υποκείμενα των δεδομένων του έτους 2008 φαίνονται στον Πίνακα 6.1. Με αυτές τις πληροφορίες, τα χαρακτηριστικά λογαριθμικής ισχύος ζώνης υπολογίζονται από τις ζώνες συχνοτήτων που παρουσιάζουν το υψηλότερο ΔPD . Για παράδειγμα, το εύρος συχνοτήτων μεταξύ 9 και 11Hz έχει επιλεγεί για το πρώτο υποκείμενο από τα δεδομένα του 2008.

6.2.2 Διακριτός Μετασηματισμός Κυματιδίων

Σε αντίθεση με τις προηγούμενες μεθόδους που αναλύσαμε, η εφαρμογή του Διακριτού Μετασηματισμού Κυματιδίων (ΔΜΚ) για την εξαγωγή χαρακτηριστικών δεν απαιτεί ζωνοπερατό φίλτράρισμα των ζωνών άλφα και βήτα. Για το σετ δεδομένων του 2003, το οποίο έχει δειγματοληφθεί με συχνότητα $F_s = 128Hz$, η εφαρμογή ΔΜΚ επιπέδου 6 με τη χρήση ενός κυματιδίου Daubechies αναλύει το σήμα ΗΕΓ στους συντελεστές λεπτομέρειας $D1 - D6$ και στον συντελεστή προσέγγισης $A6$. Όπως φαίνεται στον Πίνακα 6.2, οι συντελεστές $D3$ αντιστοιχούν στην ζώνη

Πίνακας 6.2: Συντελεστές Διακριτού Μετασχηματισμού Κυματιδίων επιπέδου 6 σήματος ΗΕΓ με συχνότητα δειγματοληψίας $128Hz$.

Συντελεστής ΔΜΚ	Εύρος Συχνοτήτων
$D1$	$32 - 64Hz$
$D2$	$16 - 32Hz$
$D3$	$8 - 16Hz$
$D4$	$4 - 8Hz$
$D5$	$2 - 4Hz$
$D6$	$1 - 2Hz$
$A6$	$0 - 1Hz$

άλφα, ενώ οι συντελεστές $D2$ αντιστοιχούν στην κεντρική ζώνη βήτα. Σημειώνεται πως για κάθε επίπεδο ανάλυσης, ο αριθμός των δειγμάτων διαιρείται με το 2. Οι υποζώνες που έχουν υποστεί ανάλυση κυματιδίων φαίνονται στο Σχήμα 6.2.

Τα στατιστικά χαρακτηριστικά εξάγονται από τις υποζώνες που αντιστοιχούν στα κύματα άλφα και βήτα. Τα χαρακτηριστικά που υπολογίζονται είναι ο μέσος όρος της απόλυτης τιμής των συντελεστών κυματιδίων, καθώς και η τυπική απόκλιση των σχετικών συντελεστών υποζώνης $D2$ και $D3$, τα οποία αναπαριστούν την κατανομή συχνότητας και το πλήθος αλλαγών σε αυτή. Έτσι, για κάθε κανάλι εξάγονται 4 τιμές, ονομαστικά ο μέσος όρος και η τυπική απόκλιση που αντιστοιχούν στις υποζώνες άλφα και βήτα. Επιπρόσθετα, γίνεται χρήση της ισχύος των συντελεστών προσέγγισης $A6$ για τα σήματα $C3$ και $C4$, δεδομένου ότι υποδεικνύει τη δραστηριότητα των δύο εγκεφαλικών ημισφαιρίων [99].

6.2.3 Κωδικοποίηση κατα μήκος των δοκιμών

Οι ταξινομητές συχνά παρέχουν γενικευμένες εκτιμήσεις και συνεπώς έχουν χαμηλή απόδοση σε δεδομένα Ηλεκτροεγκεφαλογραφήματος, αφού τα σήματα εμφανίζουν διαφορετικά χαρακτηριστικά για διαφορετικά υποκείμενα και συνεδρίες καταγραφής. Επιπλέον, η απόκτηση μεγάλων σετ δεδομένων υψηλής ποιότητας για μεμονωμένα υποκείμενα αποδεικνύεται σημαντικά δύσκολη, μιας και οι εκτέλεση νοητικών κινήσεων είναι αρκετά κουραστική για μεγάλες χρονικές περιόδους. Με στόχο, λοιπόν, την εύρεση συστατικών των σημάτων τα οποία είναι σταθερά για όλες τις δοκιμές της ίδιας κλάσης, ως σχέδιο εκπαίδευσης του δικτύου επιλέχθηκε η κωδικοποίηση κατα



Σχήμα 6.2: Ανάλυση κυματιδίων των σημάτων $C3$ και $C4$ που αντιστοιχούν σε νοητικές κινήσεις του αριστερού χεριού.

μήκος των δοκιμών (cross-trial encoding). Ακολουθώντας την μεθοδολογία των Stober et al. [96], θα παράξουμε νέα δεδομένα με σκοπό την βελτίωση της ικανότητας γενίκευσης του δικτύου.

Υπολογίζουμε τους μέσους όρους όλων των συνδυασμών που αποτελούνται από δύο δοκιμές του αρχικού σετ δεδομένων X_{org} και κάθε ένας χρησιμοποιείται ως μία νέα δοκιμή $x_{i,k}$ για επιπρόσθετη εκπαίδευση.

$$x_{new,ik} = \frac{x_i + x_k}{2} \quad (6.7)$$

, όπου x_i και x_k δοκιμές του αρχικού συνόλου δεδομένων X_{org} . Ο συνολικός αριθμός δοκιμών n_{new} από το νέο σετ δεδομένων X_{new} που παράχθηκε υπολογίζεται ως εξής:

$$n_{new} = \sum_{i=1}^C \frac{n_i(n_i + 1)}{2} \quad (6.8)$$

, δεδομένης δοκιμής n_i και κλάσης c_i που ανήκει στο σύνολο των κλάσεων C του σετ δεδομένων X_{org} . Με την εφαρμογή της κωδικοποίησης κατα μήκος των δοκιμών σε 100 προεπεξεργασμένες δοκιμές των δεδομένων του έτους 2008 από τις οποίες έχουν εξαχθεί χαρακτηριστικά ισχύος ζώνης συχνοτήτων, παράχθηκαν 2546 δείγματα και για τις δύο κλάσεις του προβλήματος.

6.3 Υλοποίηση Νευρωνικού Δικτύου Αιχμών

Σε αυτή την Ενότητα θα αναλύσουμε την υλοποίηση του Νευρωνικού Δικτύου Αιχμών που βασίζεται στο οσφρητικό σύστημα εντόμων, όπως αυτό περιγράφηκε στην Ενότητα 4.3 και το οποίο θα χρησιμοποιήσουμε για την ταξινόμηση των χαρακτηριστικών που έχουν εξαχθεί από τα διαθέσιμα δεδομένα με βάση τις μεθόδους που περιγράφηκαν στην Ενότητα 6.2. Στόχος του δικτύου θα είναι η αποκωδικοποίηση των προθέσεων κίνησης από τα σήματα ΗΕΓ που έχουν καταγραφεί. Το ΝΔΑ θα υλοποιηθεί έτσι ώστε να είναι δυνατή η εκτέλεση και ο έλεγχός του στην πλατφόρμα νευρομορφικού υλικού SpiNNaker (Ενότητα 2.3.5) με τη βοήθεια της βιβλιοθήκης PyNN [16] της γλώσσας Python.

6.3.1 Κωδικοποίηση Χαρακτηριστικών

Όπως έχουμε ήδη αναφέρει στην Ενότητα 2.3.2, ως Νευρωνική Κωδικοποίηση ορίζουμε την διαδικασία παραγωγής μοτίβων αιχμών από τα ερεθίσματα εισόδου, τα οποία αναπαρίστανται ως πραγματικές τιμές. Για την μετατροπή των χαρακτηριστικών που έχουν εξαχθεί σε αναπαραστάσεις αιχμών θα ελεγχθούν δύο διαφορετικές προσεγγίσεις κωδικοποίησης, ονομαστικά η Κωδικοποίηση Πληθυσμού και η Χρονική Κωδικοποίηση Πληθυσμού.

Κωδικοποίηση Πληθυσμού

Επικαλούμενοι τις διαφορετικές μεθόδους κωδικοποίησης που περιγράφηκαν στην Ενότητα 2.3.2, θυμόμαστε πως με βάση την Κωδικοποίηση Πληθυσμού οι πραγματικές τιμές εισόδου αντιστοιχίζονται σε ακολουθίες από αιχμές με τη χρήση Γκαουσιανών δεκτικών πεδίων. Στα πλαίσια της δεδομένης εργασίας, κάθε ένα από τα χαρακτηριστικά που έχει εξαχθεί κωδικοποιείται χρησιμοποιώντας 20 νευρώνες πληθυσμού, η ενεργοποίηση των οποίων καθορίζεται από μία Γκαουσιανή συνάρτηση. Οι τιμές των χαρακτηριστικών βρίσκονται στο διάστημα $[0, 2]$, στο οποίο εκτείνονται ομοιόμορφα 20 Γκαουσιανές κατανομές με διακύμανση $\sigma = 0.025$ (βλέπε Σχήμα 2.11). Κάθε Γκαουσιανή κατανομή αντιστοιχεί σε έναν νευρώνα πληθυσμού i και καθορίζει τον ρυθμό πυροδότησής του $R_{j,i}$ με βάση τον ακόλουθο τύπο:

$$R_{j,i} = \mathcal{N}(x_j | \mu_i, \sigma) \quad (6.9)$$

, όπου x_j το j -οστό χαρακτηριστικό του συνόλου δεδομένων και μ_i η i -οστή Γκαουσιανή μέση τιμή.

Η ενεργοποίηση των διαφορετικών νευρώνων πληθυσμού υλοποιήθηκε στην πλατφόρμα SpiNNaker ως ένας Πίνακας Αιχμών Εισόδου (Spike Source Array) με βάση το πρότυπο PyNN. Για περισσότερες πληροφορίες σχετικά με την προσομοίωση εισόδων νευρωνικού δικτύου με προκαθορισμένα χαρακτηριστικά παραπέμπουμε στο Κεφάλαιο 3, όπου αναλύεται η χρήση του PyNN.

Χρονική Κωδικοποίηση Πληθυσμού

Σε συνέχεια της προηγούμενης μεθόδου, εξετάστηκε το αποτέλεσμα της προσθήκης χρονικής πληροφορίας στην τεχνική Κωδικοποίησης Πληθυσμού. Πιο συγκεκριμένα, για κάθε νευρώνα i προστέθηκε στον ήδη υπολογισμένο ρυθμό πυροδότησης $R_{j,i}$ μία καθυστέρηση, αντιστρόφως ανάλογη με την τιμή του χαρακτηριστικού. Ο νέος ρυθμός $R'_{j,i}$ υπολογίζεται ως εξής:

$$R'_{j,i} = \mathcal{N}(x_j | \mu_i, \sigma) + \frac{R_{j,max}}{R_{j,i}} \quad (6.10)$$

, όπου $R_{j,max}$ ο μέγιστος ρυθμός όλων των νευρώνων του χαρακτηριστικού j .

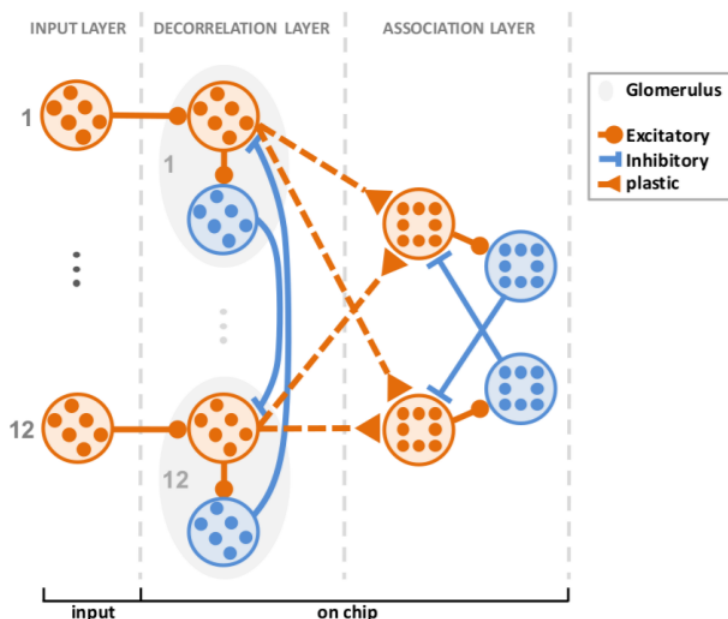
6.3.2 Υλοποίηση Δικτύου

Αρχιτεκτονική

Η αρχιτεκτονική του Νευρωνικού Δικτύου υλοποιήθηκε με βάση την περιγραφή της Ενότητας 4.3. Αρχικά, κάθε Πίνακας Αιχμών Εισόδου που προέκυψε από την κωδικοποίηση των εξαχθέντων χαρακτηριστικών, συνδέεται με έναν πληθυσμό νευρώνων στο επίπεδο εισόδου. Το επίπεδο εισόδου αποτελείται από 200 πληθυσμούς των 10 νευρώνων, οι οποίοι συνδέονται με τη σειρά τους ένας προς έναν με το δεύτερο επίπεδο αποσυσχέτισης. Το επίπεδο αποσυσχέτισης οργανώνεται σε λειτουργικές ομάδες νευρώνων, με την κάθε μία ομάδα να αποτελείται από τον ίδιο αριθμό νευρώνων και πληθυσμών, εδώ 200×10 . Κάθε πληθυσμός στο επίπεδο αποσυσχέτισης έχει ανασταλτικές συνδέσεις/συνάψεις με άλλους πληθυσμούς με πιθανότητα 40% και διεγερτικές συνδέσεις/συνάψεις με τους νευρώνες του τρίτου επιπέδου συσχέτισης με πιθανότητα 50%. Το επίπεδο συσχέτισης αποτελείται από δύο πληθυσμούς αναστολής και δύο πληθυσμούς διεγερσης. Κάθε ανασταλτικός πληθυσμός έχει ανασταλτικές συνδέσεις με τους διεγερτικούς πληθυσμούς με πιθανότητα 70%. Η παραπάνω περιγραφή της αρχιτεκτονικής του δικτύου αναπαρίσταται οπτικά στο Σχήμα 6.3.

Μάθηση

Η απόφαση ταξινόμησης που καλείται να πάρει το δίκτυο αντιστοιχεί σε δύο πληθυσμούς του επιπέδου συσχέτισης, οι οποίοι φέρουν ετικέτες. Η πρώτη κλάση αναπαριστά τις νοητικές κινήσεις του αριστερού χεριού, ενώ η δεύτερη κλάση στις κινήσεις του δεξιού χεριού. Η διαφορά στους ρυθμούς πυροδότησης κάθε νευρώνα στο επίπεδο αποσυσχέτισης για κάθε κλάση υπολογίζεται και συγκρίνεται με ένα σταθερό κατώφλι. Κατά συνέπεια, είναι δυνατός ο καθορισμός της δραστηριότητας κάθε νευρώνα, καθώς και ο νευρώνας με τον μεγαλύτερο αριθμό αιχμών για μία δεδομένη κλάση. Αν η παραπάνω διαφορά ξεπεράσει το κατώφλι αποδοχής για μία κλάση, η σύνδεση μεταξύ του συσχετισμένου πληθυσμού στο δεύτερο επίπεδο και του πληθυσμού νευρώνων συσχέτισης που αναπαριστούν την ίδια κλάση στο επίπεδο εξόδου, ενισχύεται με μία συγκεκριμένη τιμή βάρους.



Σχήμα 6.3: Το μοντέλο του Νευρωνικού Δικτύου Αιχμών των Schumaker et al. [63].

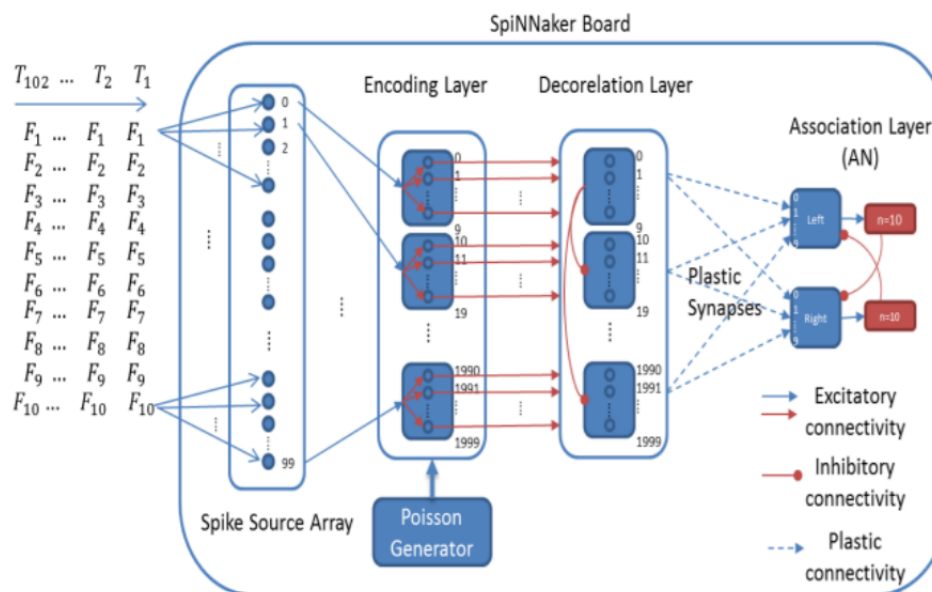
Για την βελτιστοποίηση των βαρών μεταξύ του επιπέδου συσχέτισης και του επιπέδου αποσυσχέτισης, υλοποιήθηκε ένα μοντέλο του αλγορίθμου STDP, όπως αυτός περιγράφηκε στην Ενότητα 2.3.4. Ο αλγόριθμος STDP τροποποιήθηκε κατάλληλα ώστε να περιλαμβάνει ένα σήμα επίβλεψης. Όταν μία δοκιμή εισέρχεται στο δίκτυο, ένα σήμα ανταμοιβής υπό τη μορφή μίας μετασυναπτικής αιχμής εγχέεται στον πληθυσμό νευρώνων που αντιστοιχεί στην κλάση της δοκιμής στο επίπεδο συσχέτισης. Η αιχμή αυτή πυροδοτεί τον αλγόριθμο STDP και αυξάνει τα βάρη που συνδέουν τα επίπεδα αποσυσχέτισης και συσχέτισης.

Παράμετροι Δικτύου

Στόχος μας είναι η βελτιστοποίηση του δικτύου μέσω του αλγορίθμου STDP, η οποία μεταφράζεται σε βελτιστοποίηση των βαρών του δικτύου. Πιο συγκεκριμένα, τα βάρη που πρέπει να τροποποιηθούν είναι τα ακόλουθα:

- Τα βάρη των συνδέσεων του Πίνακα Αιχμών Εισόδου με το επίπεδο κωδικοποίησης ($w_{ssa \rightarrow enc}$)
- Τα βάρη των συνδέσεων του επιπέδου κωδικοποίησης με το επίπεδο αποσυσχέτισης ($w_{enc \rightarrow dec}$)
- Τα βάρη των ανασταλτικών συνδέσεων μέσα στο επίπεδο αποσυσχέτισης ($w_{inh, dec}$)
- Τα βάρη των συνδέσεων του επιπέδου αποσυσχέτισης με το επίπεδο συσχέτισης ($w_{dec \rightarrow assoc}$)
- Τα βάρη των ανασταλτικών συνδέσεων μέσα στο επίπεδο συσχέτισης ($w_{inh, assoc}$)
- Τα βάρη των συνδέσεων ανταμοιβής του Πίνακα Αιχμών Εισόδου με το επίπεδο συσχέτισης ($w_{ssa \rightarrow assoc}$)
- Τα βάρη των συνδέσεων των Γεννητριών Poisson με το επίπεδο κωδικοποίησης ($w_{poiss \rightarrow enc}$)

Η καθυστέρηση των προβολών τέθηκε στο $1ms$. Οι νευρώνες του δικτύου είναι τύπου Leaky Integrate-and-Fire, ενώ οι συνάψεις είναι εκθετικές και εξαρτώμενες από το ρεύμα. Επιπρόσθετα, χρησιμοποιήθηκαν 60 Γεννήτριες Poisson, οι οποίες είναι υπεύθυνες για την διέγερση του επιπέδου



Σχήμα 6.4: Υλοποίηση του Νευρωνικού Δικτύου Αιχμών στην πλατφόρμα νευρομορφικού υλικού SpiNNaker [99].

εισόδου με ρυθμό πυροδότησης στα $10Hz$. Στο Σχήμα 6.4 αναπαρίστανται γραφικά οι παράμετροι του Νευρωνικού Δικτύου Αιχμών στην πλατφόρμα νευρομορφικού υλικού SpiNNaker.

Ομοιότητα

Για την περαιτέρω βελτιστοποίηση της επίδοσης του δικτύου ελέγχθηκε η μέθοδος της Ομοιότητας (Homeostasis) [82], με βάση την οποία ένα δίκτυο αιχμών μπορεί να κανονικοποιεί τα βάρη του κατά τη διάρκεια της εκπαίδευσης. Για το σκοπό αυτό, το σύνολο δεδομένων του 2008, το οποίο περιέχει 100 προεπεξεργασμένα δείγματα χωρίστηκε σε 9 τμήματα εκπαίδευσης μεγέθους 10 δειγμάτων, και σε ένα σύνολο ελέγχου με τα υπόλοιπα 10 δείγματα. Αφού το δίκτυο εκπαιδευτεί στο τμήμα i , όπου $i \in [1, 9]$, τα βάρη w_i του δικτύου πολλαπλασιάζονται με μία σταθερά γ , όπου $\gamma \in [0, 1]$, με το 0 να αναπαριστά την κατάσταση όπου το δίκτυο δεν μαθαίνει και το 1 την διαδικασία μάθησης χωρίς την Ομοιότητα. Έπειτα, το δίκτυο εκπαιδεύεται περαιτέρω χρησιμοποιώντας τα βάρη $w_{i,new}$ στα υπόλοιπα τμήματα.

$$w_{i,new} = \gamma * w_i \quad (6.11)$$

Η μέθοδος αυτή αποσκοπεί στην ελάττωση της επίδρασης μεμονωμένων δειγμάτων που προκαλούν μεγάλες αλλαγές στα βάρη του δικτύου και ως εκ τούτου αναμένεται να οδηγεί σε καλύτερη ικανότητα γενίκευσης. Εργασίες της διαθέσιμης βιβλιογραφίας, αλλά και έλεγχοι στο υλοποιημένο δίκτυο, φαίνεται να δείχνουν πως οι τιμές του γ που οδηγούν σε καλύτερα αποτελέσματα κυμαίνονται από 0.7 έως 1. Αν η τιμή του είναι πολύ μικρή, η πληροφορία που μαθαίνει το δίκτυο μέσα από την αλλαγή των βαρών του, μειώνεται σημαντικά και κατα συνέπεια και η ορθότητα ταξινόμησης του δικτύου.

Ακόμα, είναι αναγκαίο να προσαρμοστούν κατάλληλα τόσο η παράμετρος ενημέρωσης των βαρών του αλγορίθμου STDP A_+ όσο και το πλάτος του παραθύρου τ_+ , όταν η τιμή του γ αλλάζει, ώστε να εξισορροπηθεί η ευρύτερη μείωση των βαρών. Όσο πιο μικρό επιλεγεί το γ , τόσο πιο ψηλές θα πρέπει να είναι οι τιμές των A_+ και τ_+ .

Μαζική Μάθηση και Κωδικοποίηση κατα μήκος των δοκιμών

Δεδομένου ότι οι περισσότεροι αλγόριθμοι μάθησης σε νευρωνικά δίκτυα επωφελούνται από μεγαλύτερα σύνολα εκπαίδευσης, ελέγχθηκε η μέθοδος της κωδικοποίησης κατα μήκος των δοκιμών για την δημιουργία επιπρόσθετων δειγμάτων στο υλοποιημένο Νευρωνικό Δίκτυο Αιχμών, όπως αυτή περιγράφηκε στην Ενότητα 6.2.3. Η τεχνική αυτή εφαρμόστηκε στα χαρακτηριστικά ισχύος ζώνης συχνότητων του συνόλου δεδομένων του έτους 2008, οδηγώντας στην παραγωγή συνολικά 2646 δειγμάτων, συμπεριλαμβανομένου και των αρχικών 100 δοκιμών.

Σημειώνεται πως επειδή το σύνολο δεδομένων δεν μπορεί να "χωρέσει" ολόκληρο στη μνήμη της πλακέτας SpiNNaker, η οποία αποτελείται από 4 τσιπ, τα δεδομένα χωρίστηκαν σε 10 τμήματα. Στη μαζική μέθοδο επιβλεπόμενης μάθησης οι προσαρμογές στα βάρη του δικτύου εκτελούνται μετά από την παρουσίαση όλων των παραδειγμάτων εκπαίδευσης τα οποία αποτελούν μια εποχή (epoch) εκπαίδευσης. Για να εξισορροπηθεί ο μεγάλος αριθμός δειγμάτων εκπαίδευσης, οι παράμετροι του αλγορίθμου STDP προσαρμόστηκαν κατάλληλα, ώστε τα βάρη του STDP να παραμείνουν στο διάστημα 0.0 nA με 0.4 nA .

6.4 Αποτελέσματα

6.4.1 Στατιστικοί Ταξινομητές

Πριν την αξιολόγηση του υλοποιημένου Νευρωνικού Δικτύου Αιχμών, θα ελέγξουμε πρώτα την ποιότητα των χαρακτηριστικών που έχουν εξαχθεί μέσω στατιστικών ταξινομητών, εξακριβώνοντας παράλληλα την ικανότητα ταξινόμησής τους στα διαθέσιμα δεδομένα. Αυτό θα μας επιτρέψει αργότερα να συγκρίνουμε την απόδοση και λειτουργία των δύο τύπων ταξινομητών, αλλά και να εξαγάγουμε γενικότερα συμπεράσματα σχετικά με τις δύο γενεές αλγορίθμων μηχανικής μάθησης. Οι στατιστικοί ταξινομητές που θα χρησιμοποιήσουμε είναι:

- Μηχανές Διανυσμάτων Υποστήριξης (Support Vector Machines - SVM) [14]
- Τυχαίο Δάσος (Random Forest) [9]
- Λογιστική Παλινδρόμηση (Logistic Regression) [15]

Σημειώνεται πως ο τρόπος λειτουργίας των παραπάνω αλγορίθμων δεν αναλύεται στην παρούσα εργασία και για αυτό προτείνεται η γνωριμία με αυτούς από την βιβλιογραφία στην οποία έχει γίνει αναφορά.

Για την αξιολόγηση των αποτελεσμάτων ταξινόμησης και την δημιουργία ενός αξιόπιστου και σταθερού μοντέλου, ο υπολογισμός της ορθότητας (accuracy) ταξινόμησης έγινε με τη χρήση της Διασταυρωμένης Επικύρωσης (Cross Validation - CV) 10 τμημάτων (10-fold) [97]. Μοναδική εξαίρεση στον τρόπο αξιολόγησης αποτελεί η κωδικοποίηση κατα μήκος των δοκιμών, στην οποία ελέγχθηκαν οι ταξινομητές με δύο τρόπους; πρώτα με χρήση της μεθόδου 10-fold CV και έπειτα με τον παραδοσιακό διαχωρισμό των δεδομένων σε σετ εκπαίδευσης και σετ ελέγχου. Στην τελευταία περίπτωση, χρησιμοποιήθηκαν 2500 από τα νέα χαρακτηριστικά που παράχθηκαν για την εκπαίδευση και τα αρχικά 100 δείγματα για τον έλεγχο της ορθότητας ταξινόμησης.

Συνολικά, τα χαρακτηριστικά που προέκυψαν μετά την εφαρμογή του Διακριτού Μετασχηματισμού Κυματιδίων απέδωσαν τα καλύτερα αποτελέσματα, με τον ταξινομητή τύπου Random Forest να οδηγεί σε απόδοση 78.0%. Οι παραπάνω τιμές είναι σε συνέπεια με τα συμπεράσματα που προέκυψαν από τη βιβλιογραφία [94, 57], τα οποία δείχνουν πως οι μέθοδοι που κάνουν χρήση κυματιδίων φαίνεται να ξεπερνούν σε επιδόσεις τις άλλες τεχνικές εξαγωγής χαρακτηριστικών που εξετάσαμε. Τυπικά αναφέρουμε πως οι Sivakami et al. [94] πέτυχαν υψηλότερη ορθότητα ταξινόμησης 72%, ενώ οι Li et al. [57] 89.29%. Οι διαφορές στις τιμές ανάμεσα στις διαφορετικές εργα-

σίες, συμπεριλαμβανομένου και της παρούσας, φαίνεται να αποδίδονται στη χρήση διαφορετικών βημάτων ή/και μεθόδων προεπεξεργασίας των δεδομένων.

Πίνακας 6.3: Αποτελέσματα¹ ταξινόμησης δεδομένων με τη χρήση στατιστικών ταξινομητών.

Χαρακτηριστικά	SVM	Random Forest	Logistic Regression
Ισχύς Ζώνης Συχνοτήτων	74.7%(±6.9%)	76.5%(±2.5%)	77.9%(±4.3%)
ERD/ERS	65.2%(±8.7%)	63.1%(±10.3%)	64.0%(±9.5%)
Λογαριθμική Ισχύς Ζώνης Συχνοτήτων	63.7%(±3.2%)	65.6%(±6.2%)	58.8%(±5.5%)
Διακριτός Μετασχηματισμός Κυματιδίων	75.4%(±7.9%)	78.0%(±6.8%)	73.5%(±8.8%)
Κωδικοποίηση κατα μήκος των δοκιμών	77.1%	78.4%	58.9%
Κωδικοποίηση κατα μήκος των δοκιμών (10-fold CV)	91.6%(±4.4%)	88.9%(±2.6%)	85.2%(±3.5%)

Ακόμα επιβεβαιώνουμε τα βήματα που ακολουθήσαμε με βάση την δουλειά των Tayeb et al. [99] για την εξαγωγή χαρακτηριστικών ισχύος ζώνης συχνοτήτων, δεδομένου ότι πέτυχαν ορθότητα ταξινόμησης 75.0% με τη χρήση του ταξινομητή SVM, ενώ στην παρούσα εργασία επιτεύχθηκε ορθότητα 74.7% με τον ίδιο αλγόριθμο ταξινόμησης.

Η μέθοδος κωδικοποίησης κατα μήκος των δοκιμών, όπως ήταν αναμενόμενο, ενίσχυσε σημαντικά την ικανότητα γενίκευσης και των τριών αλγορίθμων που χρησιμοποιήθηκαν σε συνδυασμό με τα χαρακτηριστικά ισχύος υποζώνης, ιδιαίτερα με την εφαρμογή της τεχνικής Cross Validation.

6.4.2 Νευρωνικό Δίκτυο Αιχμών

Ένα μεγάλο μέρος αυτής της εργασίας ήταν η βελτιστοποίηση των παραμέτρων του υλοποιημένου δικτύου, δεδομένου ότι αυτές είναι που καθορίζουν εάν και κατά πόσο το δίκτυο μαθαίνει να ταξινομεί τις νοητικές κινήσεις από τα διαθέσιμα δεδομένα ΗΕΓ. Η πρώτη προσπάθεια για εφαρμογή του αλγορίθμου επίβλεψης STDP, έδειξε διακύμανση στις ακρίβειες ταξινόμησης. Μετά από την εκτέλεση βελτιστοποίησης υπερπαραμέτρων με τη χρήση του αλγορίθμου Αναζήτησης Πλέγματος (Grid Search) στις παραμέτρους του STDP και των συνδέσεων του δικτύου, αλλά και στο πλήθος των εποχών στις οποίες τα δεδομένα παρουσιάζονται στο δίκτυο, επιτεύχθηκε μέση ορθότητα 94.7%(±5.8%) με τη χρήση της τεχνικής Cross Validation 10-τμημάτων και των παραμέτρων που παρουσιάζονται στον Πίνακα 6.4 σε ένα μικρό υποσύνολο των δεδομένων.

Όταν παρουσιάστηκαν περαιτέρω χαρακτηριστικά ΗΕΓ ισχύος ζώνης συχνοτήτων από το σύνολο δεδομένων του 2008 στο δίκτυο, τα αποτελέσματα που λάβαμε ήταν αρκετά ασταθή με ακρίβειες μεταξύ 35% και 75% για όλους τους συνδυασμούς παραμέτρων του δικτύου και του αλγορίθμου STDP που δοκιμάστηκαν. Για την διατήρηση σταθερών ακριβειών ταξινόμησης ελέγχθηκε η επίδραση της απαλοιφής όλων των τυχαίων παραγόντων από το δίκτυο. Αρχικά, οι πιθανότητες των συνδέσεων του αλγορίθμου STDP, καθώς και οι πιθανότητες των ανασταλτικών συνδέσεων στο επίπεδο εξόδου αντικαταστάθηκαν από προκαθορισμένες συνδέσεις. Ακόμα, αποσυνδέθηκε από το δίκτυο η γεννήτρια θορύβου Poisson, ενώ έγινε χρήση σταθερών τιμών για τον υπολογισμό του χρονισμού των αιχμών.

¹ Σε κάθε πεδίο αποτελέσματος αναφέρεται ο μέσος όρος μαζί με μία εκτίμηση της τυπικής απόκλισης, η οποία αναπαριστά την ποικιλομορφία μεταξύ των διαφορετικών τμημάτων (folds), όπου χρησιμοποιήθηκε η μέθοδος CV.

Πίνακας 6.4: Βέλτιστοι παράμετροι Νευρωνικού Δικτύου Αιχμών.

Παράμετρος Δικτύου	Τιμή Παραμέτρου
Πλήθος εποχών	2
Πλήθος δοκιμών ανά εποχή	90
$w_{ssa \rightarrow enc}$	0.2 nA
$w_{enc \rightarrow dec}$	0.6 nA
$w_{inh, dec}$	0.03 nA
$w_{dec \rightarrow assoc}$	0.9 nA
$w_{inh, assoc}$	0.1 nA
$w_{ssa \rightarrow assoc}$	10 nA
$w_{poiss \rightarrow enc}$	0.2 nA
Πλάτος παραθύρου STDP τ_+	10.0
Βάρος παραμέτρου ενημέρωσης STDP A_+	0.02
Μέγιστο βάρος STDP w_{max}	0.4 nA
Ελάχιστο βάρος STDP w_{min}	0.0 nA
Καθυστέρηση προβολών	1 ms

Πίνακας 6.5: Παράμετροι του μοντέλου νευρώνων Leaky Integrate-and-Fire.

Παράμετρος Νευρώνα	Τιμή Παραμέτρου
Χωρητικότητα μεμβράνης (c_m)	0.25 nF
Χρονική σταθερά μεμβράνης (τ_m)	20 ms
Διάρκεια περιόδου μεταστροφής (τ_{refrac})	2 ms
Κατώφλι αιχμής (u_{thresh})	-50 mV
Ρεύμα απόκλισης (i_{offset})	0 nA
Δυναμικό ηρεμίας μεμβράνης (u_{rest})	-65 mV
Δυναμικό επαναφοράς μετά από αιχμή (u_{reset})	-70 mV
Χρόνος ανόδου διεγερτικού συναπτικού δυναμικού ($\tau_{syn,ex}$)	5 ms
Χρόνος ανόδου ανασταλτικού συναπτικού δυναμικού ($\tau_{syn,inh}$)	5 ms

Οι παραπάνω αλλαγές δεν φαίνεται να οδηγούν σε κάποια βελτίωση, ενώ ορισμένες απέτρεψαν το δίκτυο από το μάθει από τα δεδομένα. Απαλοιφώντας την τυχαιότητα από τις συνδέσεις δεν ενίσχυσε ούτε υποβίβασε την σταθερότητα του δικτύου και οι αποκλίσεις έμειναν αμετάβλητες. Αυτό μας υποδεικνύει πως η σύνδεση μεταξύ συγκεκριμένων πληθυσμών πριν από την εκπαίδευση δεν επηρεάζει το τελικό αποτέλεσμα. Ωστόσο, με την απαλοιφή του θορύβου Poisson, το δίκτυο σταμάτησε να μαθαίνει από τα δεδομένα, με αποτέλεσμα η μέση ορθότητα ταξινόμησης να μειωθεί σε τιμές $\sim 40\%$. Αυτό μας υποδηλώνει πως το δίκτυο χρειάζεται επιπλέον θόρυβο για να μάθει να αναγνωρίζει τις διαφορετικές παραλλαγές των χαρακτηριστικών.

Η υψηλή αστάθεια του δικτύου ξεπεράστηκε με την ελαφριά μεταβολή των παραμέτρων του μοντέλου που χρησιμοποιήθηκε για τους νευρώνες. Χρησιμοποιώντας ένα μοντέλο νευρώνων τύπου Leaky Integrate-and-Fire με σταθερό κατώφλι και εκθετικά φθίνων μετασυναπτικό ρεύμα, το οποίο ορίζεται από τις παραμέτρους που φαίνονται στον Πίνακα 6.5, το δίκτυο σταθεροποιήθηκε. Επιτεύχθηκε μέση ορθότητα ταξινόμησης 65.1% ($\pm 9.8\%$) στα εξαχθέντα χαρακτηριστικά ισχύος υποζώνης συχνοτήτων από τα δεδομένα του έτους 2008.

Επιπλέον έλεγχοι έδειξαν ότι η μείωση τόσο των εποχών εκπαίδευσης όσο και της διαστατικότητας των δεδομένων βελτίωσε την ορθότητα ταξινόμησης. Τα βέλτιστα αποτελέσματα επιτεύχθηκαν εκπαιδύοντας το Νευρωνικό Δίκτυο Αιχμών σε μόνο 2 ή 3 εποχές. Η διαστατικότητα

Πίνακας 6.6: Παράμετροι Νευρωνικού Δικτύου Αιχμών για μαζική μάθηση.

Παράμετρος Δικτύου	Τιμή Παραμέτρου
Πλήθος εποχών	1
Πλήθος δοκιμών ανά εποχή	265
Πλάτος παραθύρου STDP τ_+	10
Βάρος παραμέτρου ενημέρωσης STDP A_+	0.02
Μέγιστο βάρος STDP w_{max}	0.4 nA
Ελάχιστο βάρος STDP w_{min}	0.0 nA

του πίνακα χαρακτηριστικών ελαττώθηκε από τις 7 διαστάσεις σε μόλις 4, με τη χρήση της Ανάλυσης Κύριων Συνιστωσών (Principal Component Analysis - PCA) [107], διατηρώντας το 85.4% της διακύμανσης των δεδομένων. Παρά την μικρή απώλεια πληροφορίας κατά τη διάρκεια της μείωσης της διαστατικότητας, το δίκτυο έφτασε υψηλότερες ακρίβειες. Επιπρόσθετα, εκπαιδευόμενος το δίκτυο για λίγες μόνο εποχές αποτρέπει την υπερεκπαίδευση (overfitting)² και βελτιώνει περαιτέρω την επίδοση του δικτύου. Με τις παραπάνω τροποποιήσεις, η ορθότητα ταξινόμησης των διαθέσιμων κλάσεων μπορεί να φτάσει το 70.3% ($\pm 8.5\%$).

Αναφορικά με την τεχνική της Ομοιόστασης που περιγράφεται από την Εξίσωση 6.11, το δίκτυο παρουσίασε χαμηλότερη επίδοση με την εφαρμογή της. Συγκεκριμένα, η ορθότητα ταξινόμησης δεν βελτιώθηκε, αλλά αντιθέτως έφτασε το 64.7% (± 10.6). Σημειώνεται, πως η μεταβολή των βαρών του αλγορίθμου STDP μεταξύ των διαφορετικών εκπαιδεύσεων δεν φαίνεται να βελτιώνει την διαδικασία της μάθησης.

Ανεξάρτητα από το αν τα αποτελέσματα χωρίς την Ομοιόσταση είναι καλύτερα, η μαζική μάθηση φαίνεται να δουλεύει και θα μπορούσε να αποτελέσει μία έγκυρη επιλογή για ακόμα μεγαλύτερα σύνολα δεδομένων, τα οποία δεν "χωράνε" στη μνήμη του SpiNNaker. Οι παράμετροι της μαζικής εκπαίδευσης που εφαρμόστηκαν φαίνονται στον Πίνακα 6.6.

Η χρήση των 10 τμημάτων (batches) σε συνδυασμό με την μέθοδο 10-fold Cross Validation οδήγησε σε μέση ορθότητα ταξινόμησης 72.6% ($\pm 8.7\%$). Η διαφορά με το προηγούμενο καλύτερο αποτέλεσμα του 70.3% δεν θεωρείται βελτίωση, δεδομένου ότι το κάθε αποτέλεσμα βρίσκεται μέσα στην τυπική απόκλιση του άλλου. Παράλληλα, η εκπαίδευση του δικτύου μόνο με τη χρήση των 2500 νέων χαρακτηριστικών που παράχθηκαν από την κωδικοποίηση κατά μήκος των δοκιμών και ο έλεγχός του με τις αρχικές 100 δοκιμές, επέφερε ορθότητα 51.3% ($\pm 17.9\%$). Παρόμοια μείωση στην επίδοση μπορεί να παρατηρηθεί και με την χρήση στατιστικών ταξινομητών στο ίδιο σύνολο δεδομένων.

Συμπερασματικά, το Νευρωνικό Δίκτυο Αιχμών πέτυχε τα καλύτερα αποτελέσματα με την εκπαίδευση 3 εποχών μέσω Cross Validation 10-τμημάτων σε μία χαμηλής διαστατικότητας αντιστοίχιση του εξαχθέντος πίνακα χαρακτηριστικών DWT του συνόλου δεδομένων του 2008, σε συνδυασμό με τις παραμέτρους δικτύου που φαίνονται στον Πίνακα 6.4, τις παραμέτρους του μοντέλου νευρώνων του Πίνακα 6.5 και τη χρήση της μεθόδου Κωδικοποίησης Πληθυσμού, χωρίς την παραγωγή νέων χαρακτηριστικών. Η μέγιστη μέση ορθότητα ταξινόμησης που επιτεύχθηκε είναι 71.9%.

Από τις εναλλακτικές προσεγγίσεις που εφαρμόστηκαν για την ενίσχυση της επίδοσης του δικτύου απεδείχθησαν έγκυρες μόνο η χρήση της κωδικοποίησης κατά μήκος των δοκιμών και ο Διακριτός Μετασχηματισμός Κυματιδίων. . Τόσο η εκπαίδευση με τη χρήση της μεθόδου της Ομοιόστασης όσο και η προσθήκη χρονικής πληροφορίας με τη μέθοδο της Χρονικής Κωδικοποίησης Πληθυσμού δεν φαίνεται να αλλάζουν τα αποτελέσματα. Η παραγωγή νέων δοκιμών από

²Ως υπερεκπαίδευση ορίζεται η παραγωγή μιας ανάλυσης που αντιστοιχεί πολύ κοντά στο συγκεκριμένο σύνολο δεδομένων και μπορεί επομένως να αποτύχει στην πρόβλεψη μελλοντικών παρατηρήσεων αξιόπιστα.

Πίνακας 6.7: Σύγκριση μεταξύ διαφορετικών εργασιών ταξινόμησης νοητικών κινήσεων σε δύο κλάσεις (οι ορθότητες που παρατίθενται είναι οι μέγιστες ανά εργασία).

Εργασία	Χαρακτηριστικά	Ταξινομητής	Ορθότητα
Tayeb et al. [99]	Ισχύς Υποζώνης	SNN	70.0%
Yong et al. [110]	ERD/ERS	SVM	66.9%
Sivakami et al.[94]	ERD/ERS	ANN	70.5%
Tayeb et al. [99]	DWT	SNN	72.0%
Li et al. [57]	DWT	Naive Bayes	89.2%
Αυτή η εργασία	DWT	SNN	71.9%
Αυτή η εργασία	DWT	Random Forest	78.0%

τα εξαχθέντα χαρακτηριστικά φαίνεται να είναι κατάλληλη όταν γίνεται έλεγχος και με ένα υποσύνολο των νέων χαρακτηριστικών, αφού η εκπαίδευση του ταξινομητή στα νέα δείγματα και ο έλεγχός του στα αρχικά δείγματα, μειώνει την ορθότητα σε 51.3%.

Αξίζει να αναφερθεί, τέλος, πως οι διαφορετικές ορθότητες ταξινόμησης που πευχαίνει το δίκτυο ανά περίπτωση, παρουσιάζουν ασυνήθιστα μεγάλες αποκλίσεις. Αυτό μπορεί, αρχικά, να οφείλεται στο σχετικά μικρό μέγεθος του συνόλου δεδομένων, δεδομένης της στενής σχέσης μεταξύ της τυπικής απόκλισης και της χαρακτηριστικής ιδιότητας ενός συνόλου δεδομένων να περιέχει επαρκή πληροφορία για την περιγραφή του χώρου που αναπαριστά. Ακόμα, η θορυβώδη φύση των σημάτων που προέρχονται από τον εγκέφαλο, όπως το Ηλεκτροεγκεφαλογράφημα, ενδέχεται να επηρεάζει τη μεταβλητότητα των δεδομένων, και κατά συνέπεια και της απόκλισης που προκύπτει.

6.4.3 Σύγκριση Νευρωνικού Δικτύου Αιχμών με Στατιστικούς Ταξινομητές

Η υλοποίηση του αλγορίθμου μάθησης STDP με το επιπλέον σήμα ανταμοιβής, σε συνδυασμό με τη χρήση του Διακριτού Μετασχηματισμού Κυματιδίων για την εξαγωγή χαρακτηριστικών, οδήγησε στην ελαφριά βελτίωση (1.9%) της ορθότητας ταξινόμησης του Νευρωνικού Δικτύου Αιχμών, συγκριτικά με την υλοποίηση των Tayeb et al. [99] που βασίζεται σε χαρακτηριστικά ισχύος υποζώνης, στην οποία χρησιμοποίησαν το ίδιο μοντέλο δικτύου στο ίδιο σύνολο δεδομένων του έτους 2008. Παράλληλα, επιβεβαιώνεται η χρήση της μεθόδου του ΔΜΚ, όπως φαίνεται από την παρόμοια ορθότητα που πέτυχαν οι δύο εργασίες (71.9% και 72.0%), όταν αυτή χρησιμοποιήθηκε στην εξαγωγή χαρακτηριστικών. Στον Πίνακα 6.7 φαίνεται η σύγκριση των αποτελεσμάτων διαφορετικών εργασιών ταξινόμησης νοητικών κινήσεων σε δύο κλάσεις.

Συνολικά το ΝΔΑ δεν ξεπερνά τους στατιστικούς ταξινομητές τόσο στις δοκιμές που έγιναν όσο και στην διαθέσιμη βιβλιογραφία. Οι στατιστικοί αλγόριθμοι SVM, Random Forest και Logistic Regression πέτυχαν κατά μέσο όρο 5.23% μεγαλύτερη ορθότητα σε όλα τα σύνολα δεδομένων. Αναλυτική σύγκριση του ΝΔΑ με τους παραπάνω αλγορίθμους στα διαφορετικά χαρακτηριστικά που εξάχθηκαν γίνεται στον Πίνακα 6.8. Η μικρή διαφορά ανάμεσα στους δύο τύπους ταξινομητών υποδηλώνει πως ο περιοριστικός παράγοντας για την επίτευξη υψηλότερων ακριβειών ίσως δεν είναι το μοντέλο του δικτύου που χρησιμοποιείται, αλλά τα εξαγόμενα χαρακτηριστικά.

Από τα διαφορετικά χαρακτηριστικά των διαθέσιμων σημάτων ΗΕΓ που χρησιμοποιήθηκαν, ο Διακριτός Μετασχηματισμός Κυματιδίων επέφερε τα πιο περιεκτικά σε χρήσιμη πληροφορία. Σημειώνεται πως τα χαρακτηριστικά που αναπαριστούν νοητικές κινήσεις, συνήθως διαφέρουν μεταξύ των υποκειμένων, ενώ τα αντίστοιχα σήματα ΗΕΓ δεν είναι στάσιμα. Ο ΔΜΚ αποτελεί το πιο σύνθετο και αποδεδειγμένα αποδοτικό εργαλείο επεξεργασίας σημάτων που χρησιμοποιήθηκε, κάτι που επιβεβαιώνεται και από την δουλειά των Li et al. [57], οι οποίοι πέτυχαν ορθότητα 89.2%

Πίνακας 6.8: Σύγκριση των αποτελεσμάτων ταξινόμησης των στατιστικών ταξινομητών και του Νευρωνικού Δικτύου Αιχμών.

Χαρακτηριστικά	SNN	SVM	Random Forest	Logistic Regression
Ισχύς Ζώνης Συχνοτήτων	69.8%	74.7%	76.5%	77.9%
ERD/ERS	61.2%	65.2%	63.1%	64.0%
Λογαριθμική Ισχύς Ζώνης Συχνοτήτων	60.4%	63.7%	65.6%	58.8%
Διακριτός Μετασχηματισμός Κυματιδίων	71.9%	75.4%	78.0%	73.5%
Κωδικοποίηση κατα μήκος των δοκιμών	65.6%	77.1%	78.4%	58.9%
Κωδικοποίηση κατα μήκος των δοκιμών (10-fold CV)	72.6%	91.6%	88.9%	85.2%

χρησιμοποιώντας την τεχνική αυτή στο ίδιο σύνολο δεδομένων. Αντί να αναλύει μόνο το πεδίο της συχνότητας εντός ενός συγκεκριμένου χρονικού διαστήματος, όπως κάνουν άλλες μέθοδοι εξαγωγής χαρακτηριστικών, ο ΔΜΚ αποσυνθέτει το σήμα ενώ ταυτόχρονα διατηρεί την χρονική και συχνοτική πληροφορία του. Οι διαφορές στις διαφορετικές ακρίβειες ταξινόμησης ανά εργασία φαίνεται να οφείλονται στη χρήση διαφορετικών βημάτων και τεχνικών προεπεξεργασίας των αρχικών δεδομένων.

Οφείλει να τονιστεί πως η προσέγγιση που ακολουθήσαμε αποσκοπεί στην απόδειξη της ορθότητας της μεθόδου αποκωδικοποίησης μη επεμβατικών σημάτων του εγκεφάλου μέσω του νευρομορφικού υλικού SpiNNaker και όχι στην παρουσίαση ενός τελικού συστήματος. Η εργασία έκανε χρήση ενός μικρού τμήματος της υπολογιστικής και επεξεργαστικής ισχύς του υπό εξέταση υπολογιστικού συστήματος και κατα συνέπεια είναι αναμενόμενη η βελτίωση των αποτελεσμάτων ορθότητας με την κλιμάκωση του μοντέλου σε περισσότερο διαθέσιμο υλικό. Το γεγονός αυτό, σε συνδυασμό με την επίτευξη μειωμένου χρόνου εκπαίδευσης και κατανάλωσης ισχύος στην υλοποίηση του ίδιου μοντέλου από τους Tayeb et al. [99], μας υποδεικνύει πως τα ΝΔΑ αποτελούν μία βάσιμη εναλλακτική των κλασικών αλγορίθμων μηχανικής μάθησης για τη χρήση σε εφαρμογές ΔΕΥ.

Κεφάλαιο 7

Επίλογος

“Over the long term, symbiosis is more useful than parasitism. More fun, too. Ask any mitochondria.”

— Larry Wall

7.1 Συμπεράσματα και Μελλοντικές Επεκτάσεις

Η παρούσα εργασία εστιάζει στην δημιουργία μίας Διεπαφής Εγκεφάλου-Υπολογιστή η οποία αποκωδικοποιεί νοητικές κινήσεις από δεδομένα Ηλεκτροεγκεφαλογραφήματος μέσω νευρομορφικού υλικού. Δείξαμε πως η αρχιτεκτονική που βασίζεται στην νευροφυσιολογία πραγματικών εντόμων μπορεί επιτυχώς να ταξινομήσει σήματα ΗΕΓ νοητικών κινήσεων με τη χρήση ενός αλγορίθμου μάθησης ανταμοιβής τύπου STDP. Παρότι το αποτέλεσμα που επιτεύχθηκε βρίσκεται πολύ κοντά σε σύγκριση με άλλες συγγενείς εργασίες, η ορθότητα ταξινόμησης της νευρομορφικής αρχιτεκτονικής υστερεί από αυτή των παραδοσιακών στατιστικών αλγορίθμων μηχανικής μάθησης.

Δύο από τους αρχικούς στόχους της εργασίας δεν μπόρεσαν να πραγματοποιηθούν και συνεπώς το αντικείμενό της έπρεπε να τροποποιηθεί κατάλληλα. Μία από τις πιθανές προσεγγίσεις που θα μπορούσαμε να είχαμε ακολουθήσει, είναι η περαιτέρω κλιμάκωση του δικτύου ώστε να μπορεί να ταξινομή επιπλέον νοητικές κινήσεις. Ωστόσο, ένα τέτοιο σύστημα θα παρουσίαζε ακόμα χαμηλότερη ορθότητα (κάτω από 60%), δεδομένου ότι περισσότερες κλάσεις είναι πιο δύσκολο να ταξινομηθούν. Ο δεύτερος εναλλακτικός στόχος της εργασίας ήταν η υλοποίηση του Νευρωνικού Δικτύου Αιχμών σε μία εφαρμογή ΔΕΥ πραγματικού χρόνου για τον έλεγχο ενός ρομποτικού βραχίονα. Είναι άξιο αναφοράς, πως η σύγχρονη ταξινόμηση δεδομένων συνήθως παρουσιάζει μειωμένη ακρίβεια, αφού τα δεδομένα, στα οποία ο ταξινομητής εκπαιδεύεται, διαφέρουν από τη ροή δεδομένων που πρέπει έπειτα η ΔΕΥ να ταξινομήσει. Ακόμα, τα υποκείμενα είναι συνήθως πιο ανήσυχα σε ένα περιβάλλον σύγχρονης ΔΕΥ, σε σύγκριση με απλές καταγραφές, κάτι το οποίο αναμένεται να μειώνει περαιτέρω την απόδοση της ΔΕΥ. Αντίθετα, επιλέχθηκε η εξερεύνηση επιπλέον τεχνικών εξαγωγής χαρακτηριστικών, όπως αυτές έχουν προταθεί στην βιβλιογραφία, για την βελτίωση της επίδοσης του δικτύου. Τα αποτελέσματα που προέκυχαν από τον έλεγχο διαφόρων μεθόδων, υποδεικνύουν, πως ο υπολογισμός χαρακτηριστικών που περιέχουν ουσιώδη πληροφορία από τα σήματα ΗΕΓ είναι ένα αρκετά δύσκολο έργο, εξαιτίας της μη στάσιμης φύσης τους και της ποικιλομορφίας τους ανάμεσα στα υποκείμενα.

Για την δημιουργία μίας λειτουργικής ΔΕΥ που εκτελείται σε νευρομορφικό υλικό, θεωρείται κύριο μέλημα η εξεύρεση σταθερών χαρακτηριστικών. Ο Διακριτός Μετασχηματισμός Κυματιδίων έχει τη δυνατότητα να εξαγει τα χαρακτηριστικά που χρειάζονται για την αύξηση των

ποσοστών ταξινόμησης σε όλους τους ταξινομητές, όπως δείξαμε στην παρούσα εργασία και επιβεβαιώσαμε από αντίστοιχες εργασίες της βιβλιογραφίας.

Μία εναλλακτική προσέγγιση στο πρόβλημα της επιλογής μεθόδου εξαγωγής χαρακτηριστικών, παρουσίασαν οι Lungu et al. [63], η οποία περιγράφεται συνοπτικά στην Ενότητα 4.1. Κάνοντας χρήση της ίδιας αρχιτεκτονικής ΝΔΑ, πέτυχαν ορθότητα 89.2%, λειτουργώντας με τις πραγματικές αιχμές που εκπέμπονται από τους κινητικούς φλοιώδεις νευρώνες, χωρίς την ανάγκη για κατασκευή ενδιάμεσων αναπαραστάσεων υπό τη μορφή πραγματικών τιμών. Αυτή η μεθοδολογία πιθανότατα εκμεταλλεύεται στο μέγιστο την επεξεργασία της πληροφορίας των αιχμών σε νευρομορφικό υλικό, αφού δεν χάνεται καθόλου πληροφορία κατά τη διάρκεια της αποκωδικοποίησης χαρακτηριστικών πραγματικών τιμών σε αναπαραστάσεις αιχμών. Η αρνητική πτυχή της παραπάνω προσέγγισης είναι εμφανώς η απαίτηση για την καταγραφή της ηλεκτρικής δραστηριότητας μεμονομένων νευρώνων του κινητικού φλοιού, έργο το οποίο είναι ιδιαίτερα σύνθετο και δύσκολο.

Εκτός από την κλιμάκωση του μοντέλου ώστε να ταξινομεί πιο σύνθετες νοητικές κινήσεις του ίδιου άκρου, μία ενδιαφέρουσα μελλοντική επέκταση θα ήταν η εστίαση στο κινηματικό επίπεδο, όπου η κατεύθυνση κίνησης, η θέση και η ταχύτητα του χεριού θα μπορούσε να αποκωδικοποιηθεί από τα σήματα ΗΕΓ και να χρησιμοποιηθεί για έλεγχο νευροπροσθετικών μελών.

Ως ένας πιο μακροπρόθεσμος ερευνητικός στόχος, το μοντέλο μπορεί να βελτιωθεί περαιτέρω, με την προσθήκη ανατροφοδότησης (feedback). Αυτό μπορεί να επιτευχθεί με την αποκωδικοποίηση του Δυναμικού Λάθους (Error-related Potential - ErrP), ένα σήμα κλειδώματος χρόνου (time-locked signal), που προκαλείται όταν οι δράσεις του χρήστη δεν ταυτίζονται με τις προθέσεις του [91]. Τέτοια αποκωδικοποιημένη πληροφορία από σήματα ΗΕΓ, μπορεί να χρησιμοποιηθεί ως σήμα ανταμοιβής για μάθηση και προσαρμογή της επιθυμητής συμπεριφοράς σε μία Διεπαφή Εγκεφάλου-Υπολογιστή κλειστού βρόγχου.

Σήμερα, η ενσωμάτωση της νοημοσύνης σε ένα μεγάλο μέρος της τεχνολογίας που βρίσκεται γύρω μας, έχει γίνει κεντρικό πεδίο έρευνας, που απασχολεί διάφορες ειδικότητες επιστημόνων. Σε αυτό το πλαίσιο, η εργασία αυτή αναδεικνύει την νευρομορφική υπολογιστική ως έναν ενεργειακά αποδοτικό τρόπο για την ενσωμάτωση της μηχανικής νοημοσύνης μέσω συνεργιστικών εξελίξεων τόσο στο υπολογιστικό υλικό όσο και στους αλγόριθμους. Εστίασαμε στις αλγοριθμικές επιπτώσεις της χρήσης ενός Νευρωνικού Δικτύου Αιχμών, το οποίο βασίζεται σε υπολογισμούς που εξαρτώνται από γεγονότα, σε αντίθεση με τους υπολογισμούς πραγματικών τιμών στα συμβατικά συστήματα μηχανικής μάθησης. Περιγράφηκαν τα πλεονεκτήματα και οι περιορισμοί που προβάλλουν οι διαφορετικοί κανόνες μάθησης, όπως ο αλγόριθμος STDP με επίβλεψη, για εργασίες ταξινόμησης. Μελλοντική έρευνα στον κλάδο των αλγορίθμων, οφείλει να εκμεταλλευτεί τη δυναμική της επεξεργασίας πληροφορίας υπό τη μορφή αιχμών στο πεδίο του χρόνου, σε συνδυασμό με συμπληρωματικά νευρομορφικά σύνολα δεδομένων, τα οποία μπορούν να οδηγήσουν σε αναγνώριση προτύπων πραγματικού χρόνου. Παράλληλα, η ανάπτυξη του υπολογιστικού υλικού, οφείλει να εστιάσει σε υπολογισμούς που εξαρτώνται από τα γεγονότα, σε υπολογιστικές μονάδες που μιμούνται την δυναμική λειτουργικότητα των νευρωνικών συνάψεων και στην συστέγαση της μνήμης με τις μονάδες αυτές. Ιδιαίτερου ενδιαφέροντος είναι αναδυόμενες μη πτητικές (non-volatile) τεχνολογίες που επιτρέπουν τον επί τόπου υπολογισμό μικτών αναλογικών σημάτων. Ακόμα, αξίζουν να ερευνηθούν οι προοπτικές της βελτιστοποίησης πολλών επιπέδων, η οποία επιτρέπει τον συνσχεδιασμό αλγορίθμων και υλικού. Τέλος, η υπόσχεση για ενεργειακά αποδοτικά και νοήμονα συστήματα που βασίζονται σε αιχμές, σχεδιασμένα σε αναπτυσσόμενες υπολογιστικές πλατφόρμες, βρίσκεται σε αρμονία με το τρέχον ενδιαφέρον της ακαδημαϊκής κοινότητας για την δημιουργία γενικευμένης νοημοσύνης. Τώρα, λοιπόν, είναι η στιγμή για την ανταλλαγή ιδεών, με προσπάθειες που εκτείνονται σε πολλαπλούς κλάδους, οι οποίες αφορούν τη δημιουργία συσκευών, κυκλωμάτων, αρχιτεκτονικών και αλγορίθμων, που συνιστούν μία πραγματικά ενεργειακά αποδοτική και νοήμονα μηχανή.

7.2 Συζήτηση

7.2.1 Συμβίωση Ανθρώπου-Μηχανής

Πάνω από 55 χρόνια έχουν περάσει από τότε που ο ψυχολόγος και μηχανικός υπολογιστών Joseph Carl Robnett Licklider δημοσίευσε την εργασία του με τίτλο "Man-Machine Symbiosis" [58], αλλά το βασικό του επιχείρημα αντηχεί μέχρι και σήμερα ως μία πρόβλεψη για το όχι και τόσο μακρινό μέλλον. Το 1960 ο Licklider σημείωσε πως:

``Μια ομάδα εργασίας πολλαπλών ειδικοτήτων, η οποία εξετάζει μελλοντικά προβλήματα έρευνας και ανάπτυξης της Πολεμικής Αεροπορίας, εκτίμησε ότι το 1980 οι εξελίξεις στην τεχνητή νοημοσύνη, θα καταστήσουν δυνατή την λύση προβλημάτων από μηχανές για τους σκοπούς του στρατού. Αυτό αφήνει, ως πούμε, 5 χρόνια για την ανάπτυξη τεχνολογίας για τη συμβίωση ανθρώπου-μηχανής και 15 χρόνια για την ερευνητική χρήση της. Τα 15 μπορεί να γίνουν 10 ή 500, αλλά αυτά τα χρόνια θα είναι, πνευματικά, τα πιο δημιουργικά και φανταστικά στην ανθρώπινη ιστορία. [58]''

Σε εννοιολογικό επίπεδο, η πρόβλεψη του Licklider έχει σίγουρα επεκταθεί ώστε να περιλαμβάνει (σε χρονολογική σειρά εμφάνισής τους στην βιβλιογραφία): Βιοκυβερνητική [106], Διεπαφές Εγκεφάλου-Υπολογιστή [101], Υποβοηθούμενη Ιατρική [86], Υποβοηθούμενος Αυτοματισμός [76], Συνεργασία Ανθρώπου-Μηχανής, Επαυξημένη Νόηση [90], Γνωσιακή Κυβερνο-Συμβίωση [1, 2] και Συνεργασία Ανθρώπου και Συστημάτων Αυτοματισμού [20]. Σε τεχνικό επίπεδο, οι περισσότερες από αυτές τις ιδέες έχουν ήδη πραγματοποιηθεί.

Ο κλάδος της Υπολογιστικής Νοημοσύνης συνεχίζει να εισάγει πρωτοποριακές και ρηξικέλευθες τεχνολογίες με το ενδεχόμενο για σημαντική επιτάχυνση της συμβίωσης ανθρώπου-μηχανής. Η Βαθιά Μάθηση έχει ως αποτέλεσμα μηχανές που είναι πιο έξυπνες και προσαρμοστικές. Τα ασαφή συστήματα προσφέρουν ευκαιρίες για την παροχή πιο ανθρωπόμορφων τεχνικών επεξεργασίας και διαφάνειας ώστε να είναι πιο κατανοητό από τους ανθρώπους τι κάνουν οι μηχανές. Η Εξελικτική Υπολογιστική μπορεί να χρησιμοποιηθεί στην βελτιστοποίηση και προσαρμογή των παραπάνω συστημάτων. Η νοημοσύνη σμήνους (swarm intelligence) προσφέρει την βάση για αποτελεσματική συνεργασία μεταξύ μηχανών. Η ανάλυση συμπεριφοράς μέσω της Υπολογιστικής Νοημοσύνης μπορεί να χρησιμοποιηθεί στην μετατροπή δράσεων χαμηλού επιπέδου από ανθρώπους και μηχανές, σε έννοιες υψηλού επιπέδου.

Οι Demir et al. [69], εξερεύνησαν την επίπτωση της ανθρώπινης αντίληψης ενός αυτόνομου συστήματος σε δύο καταστάσεις. Στην ομάδα ελέγχου, μία ομάδα ανθρώπων είχε ενημερωθεί πως ο "συνθετικός" πράκτορας με τον οποίο δούλευαν ήταν αληθινός άνθρωπος. Στην πειραματική ομάδα, η ομάδα ανθρώπων γνώριζε την αλήθεια, πως ο πράκτορας με τον οποίο δούλευαν ήταν μία μηχανή. Τα αποτελέσματα που προέκυψαν προτείνουν πως οι άνθρωποι που ήταν ενημερωμένοι για την αλήθεια, ήταν σε θέση να βελτιώσουν την απόδοσή τους. Το εύρημα αυτής της εργασίας έχει σημαντικές επιπτώσεις στην αποτελεσματικότητα της συνεργασίας ανθρώπου-μηχανής. Ενώ θεωρείται, και είναι σίγουρα σημαντικό, πως η απόδοση ενός αυτόνομου συστήματος θα επηρεάσει άμεσα την εμπιστοσύνη του ανθρώπινου χειριστή στο σύστημα, οι Demir et al. [69] έδειξαν πως ακόμα και για το ίδιο αυτόνομο σύστημα, η ανθρώπινη εμπιστοσύνη μπορεί να επηρεαστεί από την ιδέα και μόνο πως μία μηχανή αποτελεί ομαδικό παίκτη σε μία εργασία.

Εάν υποθέσουμε πως οι άνθρωποι αρχίζουν με την πάροδο του χρόνου να νιώθουν πιο άνετα στην επαφή τους με τις μηχανές, κρίνεται αναγκαία η συνεχής εκπαίδευση και προσαρμογή των μηχανών, ώστε η επίδοσή τους, να συνεχίσει να ικανοποιεί την ανθρώπινη προσδοκία. Παράλληλα, ένας νέος τρόπος επικοινωνίας μεταξύ ανθρώπων και μηχανών μπορεί να αναπτυχθεί μέσω των Διεπαφών Εγκεφάλου-Υπολογιστή. Πολλά είναι τα πειράματα που έχουν διεξαχθεί στα πλαίσια εργασιών ανά την βιβλιογραφία, τα οποία υποδεικνύουν πως τα δεδομένα ΗΕΓ προσφέρουν ουσιώδη πληροφορία σχετική με την ανθρώπινη προσδοκία ενός γεγονότος, την προετοιμασία πριν

από την εκτέλεση μίας πράξης και την επεξεργασία του λάθους στον εγκέφαλο. Η γνώση αυτή είναι κρίσιμη για την επαύξηση των αυτόνομων μηχανικών βοηθών που κάνουν χρήση πληροφορίας ενός ευρύτερου γνωστικού πλαισίου για την βελτίωση της εμπειρίας αλληλεπίδρασης με τον άνθρωπο. Η διαρκής βελτίωση των επιδόσεων συστημάτων ταξινόμησης δεδομένων Ηλεκτροεγκεφαλογραφήματος, υποδηλώνουν πως είναι δυνατή η συνεχής αύξηση της ταχύτητας και της ακρίβειας της ερμηνείας της πληροφορίας που έρχεται απευθείας από τον ανθρώπινο εγκέφαλο.

Οι ιδέες που παρατίθενται σε αυτή την εργασία αποτελούν ένα πολύ μικρό κομμάτι από μία πλούσια και ποικιλόμορφη βιβλιογραφία. Επιδεικνύουν πως είναι πολλές οι ευκαιρίες για την ανάπτυξη της συμβίωσης του ανθρώπου-μηχανής που δεν έχουν ακόμα εξερευνηθεί. Το Ηλεκτροεγκεφαλογράφημα, για παράδειγμα, μπορεί να χρησιμοποιηθεί για την κατανόηση των μηχανισμών με τους οποίους οι άνθρωποι εξάγουν νόημα από την αισθητηριακή πληροφορία. Η γνώση αυτή θα μπορούσε να χρησιμοποιηθεί από τις μηχανές για την ερμηνεία της πληροφορίας με παρόμοιους τρόπους. Εάν οι άνθρωποι και οι μηχανές καταφέρουν να εξάγουν ισοδύναμες έννοιες από τα ερεθίσματα που μας περιβάλλουν, είναι λογικό να οδηγηθούμε σε μία βελτιωμένη κατανόηση μεταξύ των δύο μερών, το οποίο με τη σειρά του θα καταλήξει σε πιο αποτελεσματική αλληλεπίδραση. Αναγνωρίζουμε πως η τωρινή τεχνολογία καταγραφής μη επεμβατικού ΗΕΓ ενδεχομένως να μην διαθέτει επαρκή ανάλυση για την εξαγωγή της πληροφορίας που περιγράψαμε προηγουμένως. Ωστόσο, κοιτώντας το μέλλον με αισιοδοξία, η επιστημονικές εξελίξεις ίσως να το καταστήσουν δυνατό. Σε αυτή την περίπτωση, τα σημερινά συστήματα αλληλεπίδρασης ανθρώπου μηχανής, θα μπορούσαν να επεκταθούν ώστε να ενσωματώνουν την δυνατότητα για διαμοιρασμό της ερμηνείας τους για τον κόσμο με έναν ανθρώπινο συνεργάτη. Ελπίζω πως η παρούσα εργασία θα συνεισφέρει έστω και λίγο στην μετατροπή μίας ταχιάς αναπτυσσόμενης επιστήμης στην εκπλήρωση της υπόσχεσης του Licklider για την συμβίωση ανθρώπου-μηχανής.

7.2.2 Νευρομορφική Τεχνητή Νοημοσύνη

Μέσα από τα συμπεράσματα που προέκυψαν από την υλοποίηση του Νευρωνικού Δικτύου Αιχμών της παρούσας εργασίας, αλλά και την αντίστοιχη θεωρία που αναλύθηκε στα πρώτα Κεφάλαια, εξετάσαμε μερικούς από τους πολλούς τρόπους με τους οποίους η Νευροεπιστήμη έχει κάνει θεμελιώδεις συνεισφορές στην πρόοδο της Τεχνητής Νοημοσύνης. Σκεπτόμενοι την μελλοντική ανταλλαγή στοιχείων μεταξύ των δύο πεδίων, είναι σημαντικό να εκτιμήσουμε το γεγονός ότι οι προηγούμενες συνεισφορές της Νευροεπιστήμης στην ΤΝ, σπάνια εμπειρείχαν μία απλή μεταφορά ολοκληρωμένων λύσεων, οι οποίες μπορούσαν να υλοποιηθούν απευθείας στις μηχανές. Μάλλον, η Νευροεπιστήμη ήταν συνήθως χρήσιμη με έναν πιο έμμεσο τρόπο, διεγείροντας ερωτήματα σε αλγοριθμικό επίπεδο σχετικά με τις διαφορετικές όψεις της μάθησης σε έμβιους οργανισμούς και της νοημοσύνης τους, τα οποία ήταν μεγάλου ενδιαφέροντος για τους ερευνητές της ΤΝ και τους εφοδίασαν με τα κατάλληλα εργαλεία για την δημιουργία σχετικών μηχανισμών. Ως εκ τούτου, η προσωπική μου άποψη είναι πως η εκμετάλλευση των εξελίξεων που προέρχονται από τον κλάδο της Νευροεπιστήμης, θα επισπεύσει την πρόοδο της Τεχνητής Νοημοσύνης. Αυτή η μεταφορά γνώσης, θα είναι πιο αποτελεσματική εάν οι ερευνητές της ΤΝ εκκινήσουν ενεργές συνεργασίες με νευροεπιστήμονες για την επισήμανση των βασικών ερωτημάτων που θα μπορούσαν να απαντηθούν μέσω εμπειρικής μελέτης.

Η επιτυχής μεταφορά των γνώσεων που η Νευροεπιστήμη έχει καλύψει στην ανάπτυξη των αλγορίθμων Τεχνητής Νοημοσύνης εξαρτάται σε έναν μεγάλο βαθμό από την αλληλεπίδραση μεταξύ των ερευνητών που εργάζονται στα δύο αυτά επιστημονικά πεδία, δεδομένου ότι χρειάζεται συνεχής διαμοιρασμός απόψεων και ιδεών μεταξύ των κλάδων για την ανάπτυξη νέων στοιχείων. Στο μέλλον, ευελπιστώ πως η μεγαλύτερη συνεργασία μεταξύ των ερευνητών της Νευροεπιστήμης και της ΤΝ, καθώς και η εξακρίβωση μίας κοινής γλώσσας μεταξύ των δύο πεδίων, θα επιτρέψει τη δημιουργία ενός ενάρετου κύκλου, στον οποίο η έρευνα επιταχύνεται μέσω μοιραζόμενων θε-

ωρητικών ιδεών και κοινών εμπειρικών εξελίξεων. Πιστεύω πως η αναζήτηση για ανάπτυξη πιο ευφών συστημάτων θα οδηγήσει τελικά στην καλύτερη κατανόηση των ανθρώπινων διαδικασιών σκέψης. Η διύλιση της νοημοσύνης σε μία αλγοριθμική δομή και η σύγκρισή της με τον ανθρώπινο εγκέφαλο ίσως επιτρέψουν να γίνουν καλύτερα αντιληπτά μερικά από τα βαθύτερα μυστήρια του ανθρώπινου μυαλού, όπως η φύση της δημιουργικότητας, των ονείρων και πιθανώς μια μέρα, και της συνείδησης.

Παράρτημα

Ακρωνύμια

Ακρωνύμιο	Πλήρης Όρος
<i>Ελληνικοί Όροι</i>	
ΔΕΥ	Δ ιεπαφή Ε γκεφάλου- Υ πολογιστή
ΗΕΓ	Η λεκτρο Ε γκεφαλο Γ ράφημα
ΝΔΑ	Ν ευρωνικό Δ ίκτυο Α ιχμών
ΔΜΚ	Δ ιακριτός Μ ετασχηματισμός Κ υματιδίων
TN	Τ εχνητή Ν οημοσύνη
ΔΕΜ	Δ ιεπαφή Ε γκεφάλου- Μ ηχανής
ΝΥ	Ν ευρομορφική Υ πολογιστική
TNΔ	Τ εχνητό Ν ευρωνικό Δ ίκτυο
<i>Ξένοι Όροι</i>	
BCI	B rain- C omputer I nterface
EEG	E lectro E ncephalo G ram
SNN	S piking N eural N etwork
DWT	D iscrete W avelet T ransform
AI	A rtificial I ntelligence
BMI	B rain- M achine I nterface
NC	N euromorphic C omputing
ANN	A rtificial N eural N etwork
LIF	L eaky I ntegrate-and- F ire
STDP	S pike- T iming D ependent P lasticity
HBP	H uman B rain P roject
SVM	S upport V ector M achines
ERS	E vent- R elated S ynchronization
ERD	E vent- R elated D esynchronization
GDF	G eneral D ata F ormat
FIFF	F unctional I mage F ile F ormat
PD	P attern D ifference
CV	C ross V alidation

Βιβλιογραφία

- [1] Hussein A Abbass. Computational red teaming. Springer, 2015.
- [2] Hussein A Abbass, Eleni Petraki, Kathryn Merrick, John Harvey, and Michael Barlow. Trusted autonomy and cognitive cyber symbiosis: Open challenges. *Cognitive computation*, 8(3):385–408, 2016.
- [3] Nicola J Allen and Ben A Barres. Glia—more than just brain glue. *Nature*, 457(7230):675–677, 2009.
- [4] Brendan Z Allison, Elizabeth Winter Wolpaw, and Jonathan R Wolpaw. Brain–computer interface systems: progress and prospects. *Expert Review of Medical Devices*, 4(4):463–474, 2007.
- [5] Frederico AC Azevedo, Ludmila RB Carvalho, Lea T Grinberg, José Marcelo Farfel, Renata EL Ferretti, Renata EP Leite, Wilson Jacob Filho, Roberto Lent, and Suzana Herculano-Houzel. Equal numbers of neuronal and nonneuronal cells make the human brain an isometrically scaled-up primate brain. *Journal of Comparative Neurology*, 513(5):532–541, 2009.
- [6] Ben Varkey Benjamin, Peiran Gao, Emmett McQuinn, Swadesh Choudhary, Anand R Chandrasekaran, Jean-Marie Bussat, Rodrigo Alvarez-Icaza, John V Arthur, Paul A Merolla, and Kwabena Boahen. Neurogrid: A mixed-analog-digital multichip system for large-scale neural simulations. *Proceedings of the IEEE*, 102(5):699–716, 2014.
- [7] Guo-qiang Bi and Mu-ming Poo. Synaptic modifications in cultured hippocampal neurons: dependence on spike timing, synaptic strength, and postsynaptic cell type. *Journal of neuroscience*, 18(24):10464–10472, 1998.
- [8] Benjamin Blankertz, K-R Muller, Gabriel Curio, Theresa M Vaughan, Gerwin Schalk, Jonathan R Wolpaw, Alois Schlogl, Christa Neuper, Gert Pfurtscheller, Thilo Hinterberger, et al. The bci competition 2003: progress and perspectives in detection and discrimination of eeg single trials. *IEEE transactions on biomedical engineering*, 51(6):1044–1051, 2004.
- [9] Leo Breiman. Random forests. *Machine learning*, 45(1):5–32, 2001.
- [10] Scott C Bunce, Meltem Izzetoglu, Kurtulus Izzetoglu, Banu Onaral, and Kambiz Pourrezaei. Functional near-infrared spectroscopy. *IEEE engineering in medicine and biology magazine*, 25(4):54–62, 2006.
- [11] John H Byrne, Ruth Heidelberger, and M Neal Waxham. From molecules to networks: an introduction to cellular and molecular neuroscience. Academic Press, 2014.

- [12] Neil A Campbell, Jane B Reece, Lisa A Urry, Michael L Cain, Steven Alexander Wasserman, Peter V Minorsky, and Robert B Jackson. *Campbell biology*, 2011.
- [13] Yixiong Chen, Jin Hu, Nikola Kasabov, Zengguang Hou, and Long Cheng. Neucuberehab: A pilot study for eeg classification in rehabilitation practice based on spiking neural networks. In *International Conference on Neural Information Processing*, pages 70–77. Springer, 2013.
- [14] Corinna Cortes and Vladimir Vapnik. Support-vector networks. *Machine learning*, 20(3):273–297, 1995.
- [15] Jan Salomon Cramer. *The origins of logistic regression*. 2002.
- [16] Andrew P Davison, Daniel Brüderle, Jochen M Eppler, Jens Kremkow, Eilif Muller, Dejan Pecevski, Laurent Perrinet, and Pierre Yger. Pynn: a common interface for neuronal network simulators. *Frontiers in neuroinformatics*, 2:11, 2009.
- [17] J. Deng, W. Dong, R. Socher, L. Li, Kai Li, and Li Fei-Fei. Imagenet: A large-scale hierarchical image database. In *2009 IEEE Conference on Computer Vision and Pattern Recognition*, pages 248–255, 2009.
- [18] Emanuel Donchin, Kevin M Spencer, and Ranjith Wijesinghe. The mental prosthesis: assessing the speed of a p300-based brain-computer interface. *IEEE transactions on rehabilitation engineering*, 8(2):174–179, 2000.
- [19] Matthieu Duvinage, Thierry Castermans, Thierry Dutoit, M Petieau, T Hoellinger, C De Saedeleer, K Seetharaman, and G Cheron. A p300-based quantitative comparison between the emotiv epoc headset and a medical eeg device. *Biomedical Engineering*, 765(1):2012–2764, 2012.
- [20] Mica Endsley. *Autonomous horizons: System ‘autonomy’ in the air force—a path to the future: Volume i: Human autonomy teaming*. AF/ST TR15-01, 2015.
- [21] Nancy Foldvary-Schaefer and Madeleine M Grigg-Damberger. Identifying interictal and ictal epileptic activity in polysomnograms. *Sleep Medicine Clinics*, 7(1):39–58, 2012.
- [22] S. B. Furber, D. R. Lester, L. A. Plana, J. D. Garside, E. Painkras, S. Temple, and A. D. Brown. Overview of the spinnaker system architecture. *IEEE Transactions on Computers*, 62(12):2454–2467, 2013.
- [23] Steve Furber and Steve Temple. Neural systems engineering. *Journal of the Royal Society, Interface / the Royal Society*, 4:193–206, 05 2007.
- [24] Steve B Furber, Francesco Galluppi, Steve Temple, and Luis A Plana. The spinnaker project. *Proceedings of the IEEE*, 102(5):652–665, 2014.
- [25] Yasuyuki Futagi, Tsutomu Ishihara, Kumi Tsuda, Yasuhiro Suzuki, and Megumi Goto. Theta rhythms associated with sucking, crying, gazing and handling in infants. *Electroencephalography and clinical neurophysiology*, 106(5):392–399, 1998.
- [26] Deon Garrett, David A Peterson, Charles W Anderson, and Michael H Thaut. Comparison of linear, nonlinear, and feature selection methods for eeg signal classification. *IEEE Transactions on neural systems and rehabilitation engineering*, 11(2):141–144, 2003.

- [27] Laurent George, Fabien Lotte, Raquel Viciano Abad, and Anatole Lécuyer. Using scalp electrical biosignals to control an object by concentration and relaxation tasks: design and evaluation. In 2011 Annual International Conference of the IEEE Engineering in Medicine and Biology Society, pages 6299–6302. IEEE, 2011.
- [28] Wulfram Gerstner, Werner M Kistler, Richard Naud, and Liam Paninski. *Neuronal dynamics: From single neurons to networks and models of cognition*. Cambridge University Press, 2014.
- [29] Marc-Oliver Gewaltig and Markus Diesmann. Nest (neural simulation tool). *Scholarpedia*, 2(4):1430, 2007.
- [30] Dan FM Goodman and Romain Brette. Brian: a simulator for spiking neural networks in python. *Frontiers in neuroinformatics*, 2:5, 2008.
- [31] Alexandre Gramfort, Martin Luessi, Eric Larson, Denis A Engemann, Daniel Strohmeier, Christian Brodbeck, Roman Goj, Mainak Jas, Teon Brooks, Lauri Parkkonen, et al. Meg and eeg data analysis with mne-python. *Frontiers in neuroscience*, 7:267, 2013.
- [32] Henry Gray. *Anatomy of the human body*. 1918. Philadelphia: Lea & Febiger, 1821.
- [33] Brahim Hamadicharef, Haihong Zhang, Cuntai Guan, Chuanchu Wang, Kok Soon Phua, Keng Peng Tee, and Kai Keng Ang. Learning eeg-based spectral-spatial patterns for attention level measurement. In 2009 IEEE International Symposium on Circuits and Systems, pages 1465–1468. IEEE, 2009.
- [34] Matti Hämäläinen, Riitta Hari, Risto J Ilmoniemi, Jukka Knuutila, and Olli V Lounasmaa. Magnetoencephalography—theory, instrumentation, and applications to noninvasive studies of the working human brain. *Reviews of modern Physics*, 65(2):413, 1993.
- [35] Demis Hassabis, Dharshan Kumaran, Christopher Summerfield, and Matthew Botvinick. Neuroscience-inspired artificial intelligence. *Neuron*, 95(2):245 – 258, 2017.
- [36] Olaf Hauk, Ingrid Johnsrude, and Friedemann Pulvermüller. Somatotopic representation of action words in human motor and premotor cortex. *Neuron*, 41(2):301–307, 2004.
- [37] Donald Olding Hebb. *The organization of behavior: a neuropsychological theory*. J. Wiley; Chapman & Hall, 1949.
- [38] G. E. Hinton, J. L. McClelland, and D. E. Rumelhart. Distributed Representations, page 77–109. MIT Press, Cambridge, MA, USA, 1986.
- [39] Sara Ilstedt Hjelm and Carolina Browall. Brainball-using brain activity for cool competition. In *Proceedings of NordiCHI*, volume 7, 2000.
- [40] Alan L Hodgkin and Andrew F Huxley. Action potentials recorded from inside a nerve fibre. *Nature*, 144(3651):710–711, 1939.
- [41] Alan L Hodgkin and Andrew F Huxley. A quantitative description of membrane current and its application to conduction and excitation in nerve. *The Journal of physiology*, 117(4):500, 1952.

- [42] Ulrich Hoffmann, Jean-Marc Vesin, Touradj Ebrahimi, and Karin Diserens. An efficient p300-based brain–computer interface for disabled subjects. *Journal of Neuroscience methods*, 167(1):115–125, 2008.
- [43] Giacomo Indiveri, Elisabetta Chicca, and Rodney Douglas. Artificial cognitive systems: From vlsi networks of spiking neurons to neuromorphic cognition. *Cognitive Computation*, 1:119–127, 06 2009.
- [44] Giacomo Indiveri, Bernabé Linares-Barranco, Tara Julia Hamilton, André Van Schaik, Ralph Etienne-Cummings, Tobi Delbruck, Shih-Chii Liu, Piotr Dudek, Philipp Häfziger, Sylvie Renaud, et al. Neuromorphic silicon neuron circuits. *Frontiers in neuroscience*, 5:73, 2011.
- [45] Eugene M Izhikevich. Simple model of spiking neurons. *IEEE Transactions on neural networks*, 14(6):1569–1572, 2003.
- [46] Eugene M Izhikevich. Which model to use for cortical spiking neurons? *IEEE transactions on neural networks*, 15(5):1063–1070, 2004.
- [47] Xin Jin, Steve B Furber, and John V Woods. Efficient modelling of spiking neural networks on a scalable chip multiprocessor. In *2008 IEEE International Joint Conference on Neural Networks (IEEE World Congress on Computational Intelligence)*, pages 2812–2819. IEEE, 2008.
- [48] Antoine Joubert, Bilel Belhadj, Olivier Temam, and Rodolphe Hélot. Hardware spiking neurons design: Analog or digital? In *The 2012 International Joint Conference on Neural Networks (IJCNN)*, pages 1–5. IEEE, 2012.
- [49] Nikola Kasabov, Valery Feigin, Zeng-Guang Hou, Yixiong Chen, Linda Liang, Rita Krishnamurthi, Muhaini Othman, and Priya Parmar. Evolving spiking neural networks for personalised modelling, classification and prediction of spatio-temporal patterns with a case study on stroke. *Neurocomputing*, 134:269–279, 2014.
- [50] Nikola K Kasabov. *Evolving connectionist systems: the knowledge engineering approach*. Springer Science & Business Media, 2007.
- [51] Nikola K. Kasabov. Neucube: A spiking neural network architecture for mapping, learning and understanding of spatio-temporal brain data. *Neural Networks*, 52:62–76, 2014.
- [52] Christian A. Kothe. *Introduction to modern brain-computer interface design, lecture 2: Eeg basics*, 2012.
- [53] Dean J Krusienski, Eric W Sellers, Dennis J McFarland, Theresa M Vaughan, and Jonathan R Wolpaw. Toward enhanced p300 speller performance. *Journal of neuroscience methods*, 167(1):15–21, 2008.
- [54] John Lazzaro and John Wawrzynek. A multi-sender asynchronous extension to the aer protocol. In *Proceedings Sixteenth Conference on Advanced Research in VLSI*, pages 158–169. IEEE, 1995.
- [55] R Leeb, C Brunner, G Müller-Putz, A Schlögl, and G Pfurtscheller. Bci competition 2008–graz data set b. *Graz University of Technology, Austria*, pages 1–6, 2008.

- [56] Eric Leuthardt, Kai Miller, Gerwin Schalk, Rajesh Rao, and Jeffrey Ojemann. Electroencephalography-based brain computer interface—the seattle experience. *Neural Systems and Rehabilitation Engineering, IEEE Transactions on*, 14:194 – 198, 07 2006.
- [57] Mingai Li, Meng Zhang, Xinyong Luo, and Jinfu Yang. Combined long short-term memory based network employing wavelet coefficients for mi-eeeg recognition. In *2016 IEEE International Conference on Mechatronics and Automation, pages 1971–1976. IEEE, 2016.*
- [58] JCR Licklider. Man-machine symbiosis. *IRE Transactions on Human Factors in Electronics*, 1:4–11, 1960.
- [59] TA Lin and LR John. Quantifying mental relaxation with eeg for use in computer games. In *International conference on internet computing*, pages 409–415. Citeseer, 2006.
- [60] Bernabé Linares-Barranco, Teresa Serrano-Gotarredona, and Rafael Serrano-Gotarredona. Compact low-power calibration mini-dacs for neural arrays with programmable weights. *IEEE Transactions on Neural Networks*, 14(5):1207–1216, 2003.
- [61] Qian Liu. Deep spiking neural networks. The University of Manchester (United Kingdom), 2018.
- [62] Fabien Lotte, Junya Fujisawa, Hideaki Touyama, Rika Ito, Michitaka Hirose, and Anatole Lécuyer. Towards ambulatory brain-computer interfaces: A pilot study with p300 signals. In *Proceedings of the International Conference on Advances in Computer Entertainment Technology*, pages 336–339, 2009.
- [63] I-A Lungu, Alexa Riehle, Martin P Nawrot, and Michael Schmuker. Predicting voluntary movements from motor cortical activity with neuromorphic hardware. *IBM Journal of Research and Development*, 61(2/3):5–1, 2017.
- [64] E.N. Marieb and K. Hoehn. *Human Anatomy & Physiology*. Pearson Benjamin Cummings, 2007.
- [65] Thomas Martinetz, Klaus Schulten, et al. A” neural-gas” network learns topologies. 1991.
- [66] SG Mason, A Bashashati, M Fatourechi, KF Navarro, and GE Birch. A comprehensive survey of brain interface technology designs. *Annals of biomedical engineering*, 35(2):137—169, February 2007.
- [67] Warren Mcculloch and Walter Pitts. A logical calculus of ideas immanent in nervous activity. *Bulletin of Mathematical Biophysics*, 5:127–147, 1943.
- [68] Dennis Mcfarland and Jonathan Wolpaw. Brain-computer interfaces for communication and control. *Communications of the ACM*, 54:60–66, 05 2011.
- [69] Nathan J McNeese, Mustafa Demir, Nancy J Cooke, and Christopher Myers. Teaming with a synthetic teammate: Insights into human-autonomy teaming. *Human factors*, 60(2):262–273, 2018.
- [70] Carver Mead. *Analog VLSI and Neural Systems*. Addison-Wesley Longman Publishing Co., Inc., USA, 1989.

- [71] Paul A Merolla, John V Arthur, Rodrigo Alvarez-Icaza, Andrew S Cassidy, Jun Sawada, Filipp Akopyan, Bryan L Jackson, Nabil Imam, Chen Guo, Yutaka Nakamura, et al. A million spiking-neuron integrated circuit with a scalable communication network and interface. *Science*, 345(6197):668–673, 2014.
- [72] Christian Mühl, Hayrettin Gürkök, Danny Plass-Oude Bos, Marieke E Thurlings, Lasse Scherffig, Matthieu Duvinage, Alexandra A Elbakyan, SungWook Kang, Mannes Poel, and Dirk Heylen. Bacteria hunt. *Journal on multimodal user interfaces*, 4(1):11–25, 2010.
- [73] E Niedermeyer. The electrocerebellogram. *Clinical EEG and neuroscience*, 35(2):112–115, 2004.
- [74] Ernst Niedermeyer and FH Lopes da Silva. *Electroencephalography: basic principles, clinical applications, and related fields*. Lippincott Williams & Wilkins, 2005.
- [75] Seiji Ogawa, David W Tank, Ravi Menon, Jutta M Ellermann, Seong G Kim, Helmut Merkle, and Kamil Ugurbil. Intrinsic signal changes accompanying sensory stimulation: functional brain mapping with magnetic resonance imaging. *Proceedings of the National Academy of Sciences*, 89(13):5951–5955, 1992.
- [76] Raja Parasuraman, Toufik Bahri, John E Deaton, Jeffrey G Morrison, and Michael Barnes. *Theory and design of adaptive automation in aviation systems*. Technical report, Catholic Univ of America Washington DC cognitive science lab, 1992.
- [77] Massoud Pedram and Shahin Nazarian. Thermal modeling, analysis, and management in vlsi circuits: Principles and methods. *Proceedings of the IEEE*, 94(8):1487–1501, 2006.
- [78] Thomas Pfeil, Andreas Grübl, Sebastian Jeltsch, Eric Müller, Paul Müller, Mihai A Petrovici, Michael Schmuker, Daniel Brüderle, Johannes Schemmel, and Karlheinz Meier. Six networks on a universal neuromorphic computing substrate. *Frontiers in neuroscience*, 7:11, 2013.
- [79] Gert Pfurtscheller. Event-related synchronization (ers): an electrophysiological correlate of cortical areas at rest. *Electroencephalography and clinical neurophysiology*, 83(1):62–69, 1992.
- [80] Gert Pfurtscheller and FH Lopes Da Silva. Event-related eeg/meg synchronization and desynchronization: basic principles. *Clinical neurophysiology*, 110(11):1842–1857, 1999.
- [81] Gert Pfurtscheller and Christa Neuper. Motor imagery and direct brain-computer communication. *Proceedings of the IEEE*, 89(7):1123–1134, 2001.
- [82] L. Qu, L. Wang, S. Tian, Z. Kang, S. Li, and W. Xu. A novel homeostasis method to improve the learning efficiency of spiking neural networks. In *2019 IEEE International Workshop on Future Computing (IWOFC)*, pages 1–3, 2019.
- [83] Alexander D Rast, Xin Jin, Francesco Galluppi, Luis A Plana, Cameron Patterson, and Steve Furber. Scalable event-driven native parallel processing: the spinnaker neuromimetic system. In *Proceedings of the 7th ACM international conference on Computing frontiers*, pages 21–30, 2010.

- [84] Jane B Reece, Lisa A Urry, Michael Lee Cain, Steven Alexander Wasserman, Peter V Minorsky, Robert B Jackson, et al. *Campbell biology*. Number s 1309. Pearson Boston, 2014.
- [85] Oliver Rhodes, Petruț A Bogdan, Christian Brenninkmeijer, Simon Davidson, Donal Fellows, Andrew Gait, David R Lester, Mantas Mikaitis, Luis A Plana, Andrew GD Rowley, et al. spynnaker: a software package for running pynn simulations on spinnaker. *Frontiers in neuroscience*, 12:816, 2018.
- [86] William B Rouse. Adaptive aiding for human/computer control. *Human factors*, 30(4):431–443, 1988.
- [87] James Say, Michael F Tomasco, Adam Heller, Yoram Gal, Behrad Aria, Ephraim Heller, Phillip John Plante, and Mark S Vreeke. Electrochemical analyte sensor, November 19 2002. US Patent 6,484,046.
- [88] Johannes Schemmel, Daniel Briiderle, Andreas Griibl, Matthias Hock, Karlheinz Meier, and Sebastian Millner. A wafer-scale neuromorphic hardware system for large-scale neural modeling. In *Proceedings of 2010 IEEE International Symposium on Circuits and Systems*, pages 1947–1950. IEEE, 2010.
- [89] Alois Schlögl. Gdf-a general dataformat for biosignals. arXiv preprint cs/0608052, 2006.
- [90] DD Schmorrow and Amy A Kruse. Darpa’s augmented cognition program-tomorrow’s human computer interaction from vision to reality: building cognitively aware computational systems. In *Proceedings of the IEEE 7th Conference on Human Factors and Power Plants*, pages 7–7. IEEE, 2002.
- [91] Michael Schmuker, Thomas Pfeil, and Martin Paul Nawrot. A neuromorphic network for generic multivariate data classification. *Proceedings of the National Academy of Sciences*, 2014.
- [92] Catherine D Schuman, Thomas E Potok, Robert M Patton, J Douglas Birdwell, Mark E Dean, Garrett S Rose, and James S Plank. A survey of neuromorphic computing and neural networks in hardware. arXiv preprint arXiv:1705.06963, 2017.
- [93] Jerry J. Shih, Dean J. Krusienski, and Jonathan R. Wolpaw. Brain-computer interfaces in medicine. *Mayo Clinic Proceedings*, 87(3):268–279, March 2012.
- [94] A Sivakami, S Shenbaga Devi, et al. Analysis of eeg for motor imagery based classification of hand activities. *International Journal of Biomedical Engineering and Science*, 2(3):11–22, 2015.
- [95] Sen Song, Kenneth D Miller, and Larry F Abbott. Competitive hebbian learning through spike-timing-dependent synaptic plasticity. *Nature neuroscience*, 3(9):919–926, 2000.
- [96] Sebastian Stober, Avital Sternin, Adrian M Owen, and Jessica A Grahn. Deep feature learning for eeg recordings. arXiv preprint arXiv:1511.04306, 2015.
- [97] Mervyn Stone. Cross-validators choice and assessment of statistical predictions. *Journal of the Royal Statistical Society: Series B (Methodological)*, 36(2):111–133, 1974.

- [98] Abdulhamit Subasi and M Ismail Gursoy. Eeg signal classification using pca, ica, lda and support vector machines. *Expert systems with applications*, 37(12):8659–8666, 2010.
- [99] Zied Tayeb, Emec Ercelik, and Jörg Conradt. Decoding of motor imagery movements from eeg signals using spinnaker neuromorphic hardware. 2017 8th International IEEE/EMBS Conference on Neural Engineering (NER), pages 263–266, 2017.
- [100] A. M. Turing. Computing machinery and intelligence. *Mind*, 59(236):433–460, 1950.
- [101] Jacques J Vidal. Toward direct brain-computer communication. *Annual review of Biophysics and Bioengineering*, 2(1):157–180, 1973.
- [102] Carmen Vidaurre, Tilmann H Sander, and Alois Schlögl. Biosig: the free and open source software library for biomedical signal processing. *Computational intelligence and neuroscience*, 2011, 2011.
- [103] Pauli Virtanen, Ralf Gommers, Travis E Oliphant, Matt Haberland, Tyler Reddy, David Cournapeau, Evgeni Burovski, Pearu Peterson, Warren Weckesser, Jonathan Bright, et al. Scipy 1.0: fundamental algorithms for scientific computing in python. *Nature methods*, 17(3):261–272, 2020.
- [104] Stéfan van der Walt, S Chris Colbert, and Gael Varoquaux. The numpy array: a structure for efficient numerical computation. *Computing in science & engineering*, 13(2):22–30, 2011.
- [105] Yijun Wang, Bo Hong, Xiaorong Gao, and Shangkai Gao. Implementation of a brain-computer interface based on three states of motor imagery. In 2007 29th Annual International Conference of the IEEE Engineering in Medicine and Biology Society, pages 5059–5062. IEEE, 2007.
- [106] Norbert Wiener and Johannes Petrus Schadé. *Progress in biocybernetics*. Elsevier Publishing Company, 1964.
- [107] Svante Wold, Kim Esbensen, and Paul Geladi. Principal component analysis. *Chemometrics and intelligent laboratory systems*, 2(1-3):37–52, 1987.
- [108] Jonathan R Wolpaw and Dennis J McFarland. Control of a two-dimensional movement signal by a noninvasive brain-computer interface in humans. *Proceedings of the national academy of sciences*, 101(51):17849–17854, 2004.
- [109] Yuan Yang, Sylvain Chevallier, Joe Wiart, and Isabelle Bloch. Time-frequency optimization for discrimination between imagination of right and left hand movements based on two bipolar electroencephalography channels. *EURASIP Journal on Advances in Signal Processing*, 2014(1):38, 2014.
- [110] Xinyi Yong and Carlo Menon. Eeg classification of different imaginary movements within the same limb. *PloS one*, 10(4):e0121896, 2015.
- [111] Theodore Yu, Jongkil Park, Siddharth Joshi, Christoph Maier, and Gert Cauwenberghs. 65k-neuron integrate-and-fire array transceiver with address-event reconfigurable synaptic routing. In 2012 IEEE Biomedical Circuits and Systems Conference (BioCAS), pages 21–24. IEEE, 2012.