



**ΠΑΝΕΠΙΣΤΗΜΙΟ ΘΕΣΣΑΛΙΑΣ**  
**ΣΧΟΛΗ ΘΕΤΙΚΩΝ ΕΠΙΣΤΗΜΩΝ**  
**ΤΜΗΜΑ ΠΛΗΡΟΦΟΡΙΚΗΣ ΜΕ ΕΦΑΡΜΟΓΕΣ**  
**ΣΤΗ ΒΙΟΙΑΤΡΙΚΗ**

**Ανάλυση βιοσημάτων από συσκευή συλλογής εγκεφαλικής  
δραστηριότητας**

**Παπασωτηρίου Ευάγγελος**

**ΠΤΥΧΙΑΚΗ ΕΡΓΑΣΙΑ**

**Υπεύθυνοι**

**Πλαγιανάκος Βασίλειος, Αναπληρωτής καθηγητής**  
**Δελημπασης Κωνσταντίνος, Επίκουρος καθηγητής**

**Λαμία, Ιούνιος 2016**





**ΠΑΝΕΠΙΣΤΗΜΙΟ ΘΕΣΣΑΛΙΑΣ**  
**ΣΧΟΛΗ ΘΕΤΙΚΩΝ ΕΠΙΣΤΗΜΩΝ**  
**ΤΜΗΜΑ ΠΛΗΡΟΦΟΡΙΚΗΣ ΜΕ ΕΦΑΡΜΟΓΕΣ ΣΤΗ**  
**ΒΙΟΙΑΤΡΙΚΗ**

**Ανάλυση βιοσημάτων από συσκευή συλλογής εγκεφαλικής  
δραστηριότητας**

**Παπασωτηρίου Ευάγγελος**

**ΠΤΥΧΙΑΚΗ ΕΡΓΑΣΙΑ**

**Επιβλέποντες**

**Πλαγιανάκος Βασίλειος, Αναπληρωτής καθηγητής**

**Δελήμπασης Κωνσταντίνος, Επίκουρος καθηγητής**

**Λαμία, Ιούνιος 2016**

Με ατομική μου ευθύνη και γνωρίζοντας τις κυρώσεις <sup>(1)</sup>, που προβλέπονται από τις διατάξεις της παρ. 6 του άρθρου 22 του Ν. 1599/1986, δηλώνω ότι:

1. Δεν παραθέτω κομμάτια βιβλίων ή άρθρων ή εργασιών άλλων αυτολεξεί **χωρίς να τα περικλείω σε εισαγωγικά** και χωρίς να αναφέρω το συγγραφέα, τη χρονολογία, τη σελίδα. Η αυτολεξεί παράθεση χωρίς εισαγωγικά χωρίς αναφορά στην πηγή, είναι λογοκλοπή. Πέραν της αυτολεξεί παράθεσης, λογοκλοπή θεωρείται και η παράφραση εδαφίων από έργα άλλων, συμπεριλαμβανομένων και έργων συμφοιτητών μου, καθώς και η παράθεση στοιχείων που άλλοι συνέλεξαν ή επεξεργάστηκαν, χωρίς αναφορά στην πηγή. Αναφέρω πάντοτε με πληρότητα την πηγή κάτω από τον πίνακα ή σχέδιο, όπως στα παραθέματα.
2. Δέχομαι ότι η αυτολεξεί **παράθεση χωρίς εισαγωγικά**, ακόμα κι αν συνοδεύεται από αναφορά στην πηγή σε κάποιο άλλο σημείο του κειμένου ή στο τέλος του, είναι αντιγραφή. Η αναφορά στην πηγή στο τέλος π.χ. μιας παραγράφου ή μιας σελίδας, δεν δικαιολογεί συρραφή εδαφίων έργου άλλου συγγραφέα, έστω και παραφρασμένων, και παρουσίασή τους ως δική μου εργασία.
3. Δέχομαι ότι υπάρχει επίσης περιορισμός στο μέγεθος και στη συχνότητα των παραθεμάτων που μπορώ να εντάξω στην εργασία μου εντός εισαγωγικών. Κάθε μεγάλο παράθεμα (π.χ. σε πίνακα ή πλαίσιο, κλπ), προϋποθέτει ειδικές ρυθμίσεις, και όταν δημοσιεύεται προϋποθέτει την άδεια του συγγραφέα ή του εκδότη. Το ίδιο και οι πίνακες και τα σχέδια
4. Δέχομαι όλες τις συνέπειες σε περίπτωση λογοκλοπής ή αντιγραφής.

Ημερομηνία: ...../...../20.....

Ο – Η Δηλ.

(Υπογραφή)

(1) «Όποιος εν γνώσει του δηλώνει ψευδή γεγονότα ή αρνείται ή αποκρύπτει τα αληθινά με έγγραφη υπεύθυνη δήλωση του άρθρου 8 παρ. 4 Ν. 1599/1986 τιμωρείται με φυλάκιση τουλάχιστον τριών μηνών. Εάν ο υπαίτιος αυτών των πράξεων σκόπευε να προσπορίσει στον εαυτόν του ή σε άλλον περιουσιακό όφελος βλάπτοντας τρίτον ή σκόπευε να βλάψει άλλον, τιμωρείται με κάθειρξη μέχρι 10 ετών.

**Ανάλυση βιοσημάτων από συσκευή συλλογής εγκεφαλικής  
δραστηριότητας**

**Παπασωτηρίου Ευάγγελος**

**Τριμελής Επιτροπή:**

Πλαγιανάκος Βασίλειος, Αναπληρωτής καθηγητής (επιβλέπων)

Δελήμπασης Κωνσταντίνος, Επίκουρος καθηγητής (επιβλέπων)

Σανδαλίδης Χαρίλαος, Επίκουρος καθηγητής

**“Στους γονείς οφείλομεν το ζην, στους δε διδασκάλους το ευ ζην” Μ. Αλέξανδρος**

*Ευχαριστώ τους γονείς μου και τους καθηγητές μου  
για την υπομονή και την υποστήριξή τους.*

## Περίληψη

Σκοπός της παρούσας εργασίας είναι η καταγραφή και ανάλυση βιοσημάτων από χαμηλού κόστους, εμπορικά διαθέσιμη συσκευή καταγραφής εγκεφαλικής δραστηριότητας, ώστε να εξεταστεί η δυνατότητα χρήσης σε εφαρμογές διεπαφής εγκεφάλου – υπολογιστή (brain-computer interface – BCI). Η συσκευή δοκιμάζεται σε πειράματα σκέψης κίνησης δεξιού/αριστερού χεριού τα οποία συγκρίνονται με τα αντίστοιχα ενός διαφορετικού εγκεφαλογράφου (G.tec). Για την ανάλυση των ηλεκτροεγκεφαλογραφημάτων των δυο συσκευών εξήχθησαν διάφορα χαρακτηριστικά με την χρήση του χρονικού-συχνотικού διακριτού μετασχηματισμού wavelet, καθώς και συχνотικά χαρακτηριστικά με την χρήση ζωνοπερατών IIR(infinite impulse response) Chebychev φίλτρων. Τα χαρακτηριστικά αυτά συνδυάζονται και δημιουργούν διάφορους πίνακες, οι οποίοι δίνονται στη συνέχεια ως είσοδο ο καθένας ξεχωριστά σε γραμμικούς ταξινομητές, ταξινομητές κ κοντινότερων γειτόνων και νευρωνικά δίκτυα ενός κρυφού επιπέδου νευρώνων. Οι ταξινομητές διαχωρίζουν τα δεδομένα κάθε πίνακα χαρακτηριστικών με τυχαίο τρόπο σε δυο ίσα σετ το ένα χρησιμοποιείται από τον εκάστοτε αλγόριθμο για εκπαίδευση και το άλλο για την μέτρηση της ακρίβειας ταξινόμησης. Τα νευρωνικά δίκτυα χωρίζουν τους πίνακες χαρακτηριστικών με τυχαίο τρόπο κρατώντας το 70% για εκπαίδευση του δικτύου, το 15% για έλεγχο και αναπροσαρμογή του δικτύου κατά τη διάρκεια της εκπαίδευσης και 15% για δοκιμή του ταξινομητή μετά το τέλος της εκπαίδευσης. Κάθε ταξινομητής και νευρωνικό δίκτυο εφαρμόζεται αρκετές φορές για ένα πίνακα χαρακτηριστικών και στη συνέχεια προκύπτει η μέση ακρίβεια ταξινόμησης, δηλαδή το ποσοστό επιτυχίας με το οποίο ο αλγόριθμος αντιστοιχεί τα δεδομένα στην πραγματική κλάση που ανήκουν. Οι αλγόριθμοι εφαρμόζονται για το ίδιο διάνυσμα χαρακτηριστικών αρκετές φορές. Παρατηρείται ότι τα ποσοστά της μέσης ακρίβειας για τα δεδομένα της χαμηλού κόστους εμπορικής συσκευής για όλους τους διαφορετικούς πίνακες χαρακτηριστικών κυμαίνονται σε χαμηλά ποσοστά και σε μερικές περιπτώσεις προσεγγίζουν αυτά των βιοσημάτων του Gtec. Αντίθετα τα ποσοστά που επιτεύχθηκαν από τα βιοσήματα που συλλέχθηκαν από τον κλινικό εγκεφαλογράφο G.tec κινούνται σε υψηλότερα ποσοστά μέσης ακρίβειας, συγκρίσιμες με τις αντίστοιχες τιμές της βιβλιογραφίας.

## Λέξεις Κλειδιά:

Brain Computer Interface (BCI), Motor Imagery (MI), εξαγωγή χαρακτηριστικών (feature extraction), Διακριτός μετασχηματισμός wavelet, Ηλεκτροεγκεφαλογράφημα (HEΓ), ρυθμός β, ρυθμός μ, Αποσυντονισμός λόγω Γεγονότος (ERD), Συντονισμός λόγω Γεγονότος (ERS), ταξινομητές, μέση ακρίβεια ταξινόμησης.

## **Abstract**

This current work is focused in recording and analyzing biosignals from the brain by using a low cost of-the-shelf recording device, for brain-computer-interface applications (BCI). The device is tested in recording motor imagery experiments of right/left hand movement and the results are compared to those of a different device (G.tec). To analyze the recorded electroencephalograms (EEG) from the two devices, a variety of features was extracted, using Discrete Wavelet Transform (DWT) and band pass Infinite Impulse Response (IIR) Chebychev filters. The features that are combined to create different feature tables, which are given as inputs to linear classifiers,  $k$ -nearest neighbor classifier and artificial neural networks (ANN). The classifiers divide the data of each feature table randomly into two equal datasets. One is used by the algorithm as training dataset and the other to calculate the classification accuracy. The ANN divide the feature tables randomly keeping 70% of the dataset for training the network, 15% for checking the network during training and 15% to test classification accuracy after the training is finished. Every classifier and neural network is applied many times to a feature table and then the mean accuracy of all classifications is calculated. According to our experiments the mean accuracy for all the different feature tables and classifiers extracted from the low cost commercial device is low and in some cases it approaches the mean accuracy of G.tec. On the contrary, the mean accuracy of G.tec are in higher levels, comparable to other published work in the field of BCI.

## **Keywords:**

Brain Computer Interface (BCI), Motor Imagery (MI), feature extraction, mean classification accuracy, Discrete Wavelet Transform (DWT), electroencephalogram (EEG), beta rhythm ,mu rhythm ,event related desynchronazation (ERD), event related synchronization (ERS), linear discriminant analysis LDA, support vector machines (SVM), k nearest neighbor (kNN), multilayer perceptron (MLP).



## Περιεχόμενα

1	Εισαγωγή.....	10
1.1	Τι είναι το Ηλεκτροεγκεφαλογράφημα.....	10
1.1.1	Καταγραφή του ΗΕΓ: Το σύστημα 10-20.....	11
1.2	Διεπαφή εγκεφάλου υπολογιστή.....	12
1.3	Εμπορικά διαθέσιμα EEG προϊόντα.....	12
1.4	Μέθοδοι εξαγωγής χαρακτηριστικών για BCI motor imagery.....	13
1.4.1	Ο μετασχηματισμός wavelet.....	13
1.5	Αλγόριθμοι ταξινόμησης.....	15
1.5.1	Γραμμικοί ταξινομητές (Linear Classifiers).....	15
1.5.2	Νευρωνικά Δίκτυα (Neural Networks - Multilayer Perceptron).....	15
1.5.3	Ταξινομητές κοντινότερου γείτονα.....	16
2	Μεθοδολογία.....	16
2.1	Μέθοδος εξαγωγής χαρακτηριστικών στην παρούσα εργασία.....	16
2.1.1	Χαρακτηριστικά βασισμένα σε διακριτό μετασχηματισμό wavelet.....	16
2.1.2	Χαρακτηριστικά βασισμένα σε φίλτρα IIR Chebychev type II.....	18
2.2	Αλγόριθμοι ταξινόμησης που χρησιμοποιήθηκαν.....	20
2.2.1	Linear discriminant analysis.....	21
2.2.2	Support vector machine.....	21
2.2.3	k nearest neighbor.....	22
2.2.4	Artificial Neural Networks-Multilayer Perceptron.....	23
2.3	Ποσοτικοποίηση της ακρίβειας της ταξινόμησης.....	24
3	Δεδομένα που χρησιμοποιήθηκαν.....	25
3.1	Έτοιμα δεδομένα EEG που χρησιμοποιήθηκαν.....	25
3.2	Emotiv Eroc dataset.....	26
4	Αποτελέσματα.....	27
4.1	Διανύσματα χαρακτηριστικών BCI Competition.....	27
4.2	Ακρίβεια ταξινόμησης των data του BCI Competition.....	29
4.2.1	Linear Discriminant Analysis.....	29

4.2.2	Support Vector Machine.....	30
4.2.3	k Nearest Neighbors.....	31
4.2.4	Νευρωνικά Δίκτυα - Multilayer Perceptron.....	34
4.3	Διανύσματα χαρακτηριστικών Emotiv Eroc.....	37
4.4	Ακρίβεια ταξινόμησης των dataset του Emotiv Eroc.....	38
4.4.1	Linear Discriminant Analysis.....	39
4.4.2	Support vector machine, SVM.....	40
4.4.3	Νευρωνικά Δίκτυα - Multilayer Perceptron.....	41
4.5	Συμπεράσματα για την ακρίβεια ταξινόμησης των δεδομένων του Emotiv Eroc 42	
5	Βιβλιογραφία.....	44

# 1 Εισαγωγή

## 1.1 Τι είναι το Ηλεκτροεγκεφαλογράφημα

Το 1924 ο Γερμανός ψυχίατρος Hans Berger [1] ήταν ο πρώτος που τοποθέτησε ηλεκτρόδια στην επιφάνεια του ανθρώπινου κεφαλιού και παρατήρησε ότι λαμβάνεται σήμα ηλεκτρικής ταλάντωσης. Ονόμασε την ανακάλυψή του ηλεκτροεγκεφαλογράφημα – ΗΕΓ, (electroencephalogram - EEG).

Η λήψη του ΗΕΓ γίνεται με δυο τρόπους, ο ένας είναι με τη τοποθέτηση ηλεκτροδίων στην επιφάνεια της κεφαλής και ο δεύτερος είναι με χειρουργική τοποθέτηση στην εξωτερική μεμβράνη του εγκεφάλου [2]. Συνήθως χρησιμοποιείται η πρώτη μέθοδος και σπανιότερα η επεμβατική διαδικασία που ακολουθείται σε περιπτώσεις που απαιτείται μεγαλύτερη ακρίβεια αφού το σήμα που δίνουν οι νευρώνες είναι της τάξης των  $\mu\text{V}$  και εξασθενεί πολύ γρήγορα, πόσο μάλλον στην περίπτωση που μεσολαβεί το κρανίο. Το φάσμα του εγκεφαλογραφήματος είναι περίπου 0-100 Hz, αν και το χρήσιμο για ανάλυση σήμα περιορίζεται περίπου ως τα 30 Hz. Οι επιστήμονες έχουν χωρίσει το φάσμα του σε ζώνες συχνοτήτων βάση των χαρακτηριστικών που αναδεικνύουν. Οι κυριότεροι ρυθμοί είναι οι εξής [3]:

- Ο ρυθμός **Γάμμα (Gamma)** εμφανίζεται στις συχνότητες μεγαλύτερες των **30Hz**. Είναι σημαντικός στην μάθηση, μνήμη και επεξεργασία πληροφορίας. Έχει διαπιστωθεί ότι άτομα με μαθησιακές δυσκολίες και νοητική υστέρηση τείνουν να έχουν μικρότερη δραστηριότητα Gamma από το μέσο όρο. Υψηλή δραστηριότητα του ρυθμού οφείλεται σε άγχος, υπερένταση, αγωνία. Χαμηλή φανερώνει κατάθλιψη, μαθησιακές δυσκολίες, σύνδρομο ελλειμματικής προσοχής-υπερκινητικότητας (attention deficit hyperactivity disorder ADHD).
- Ο ρυθμός  **$\beta$  (Beta)** εμφανίζεται στις συχνότητες **12-30 Hz**. Τα κύματα αυτά χαρακτηρίζονται από χαμηλό πλάτος και παρατηρούνται κυρίως όταν κάποιος είναι ξύπνιος. Παίζουν μεγάλο ρόλο στη συνείδηση, τη λογική σκέψη, τη συγκέντρωση, την επίλυση προβλημάτων. Επίσης σχετίζονται με την πραγματοποίηση ή σκέψη κίνησης. Υψηλή δραστηριότητα του ρυθμού οφείλεται σε έκκριση αδρεναλίνης, αγωνία, υπερδιέγερση, αδυναμία ηρεμίας. Χαμηλή φανερώνει σύνδρομο ADHD, αφηρημάδα, κατάθλιψη.
- Ο ρυθμός **A (Alpha)** εμφανίζεται στις συχνότητες **8-12 Hz**. Γεφυρώνει το χάσμα ανάμεσα στη συνειδητή σκέψη και το υποσυνείδητο μυαλό. Με άλλα λόγια γεφυρώνει το χάσμα ανάμεσα στους beta και theta. Μας βοηθά να ηρεμήσουμε όποτε είναι απαραίτητο και προάγει το συναίσθημα της βαθιάς χαλάρωσης. Αν πιεστούμε τότε μπορεί να εμφανιστεί το φαινόμενο μπλοκαρίσματος των alpha κυμάτων (alpha blocking), που οδηγεί σε χαμηλό ρυθμό alpha και μεγάλη αύξηση του beta. Τέλος σχετίζεται με την πραγματοποίηση ή σκέψη κίνησης. Υψηλή δραστηριότητα προκαλεί υπερβολική χαλάρωση, αδυναμία συγκέντρωσης. Χαμηλή δραστηριότητα προκαλεί άγχος, αϋπνίες, ιδεόψυχαναγκαστική διαταραχή (obsessive compulsive disorder OCD). Αύξηση του ρυθμού μπορεί να προκληθεί από κατανάλωση αλκόολ, χαλαρωτικά φάρμακα και από μερικά αντικαταθλιπτικά.

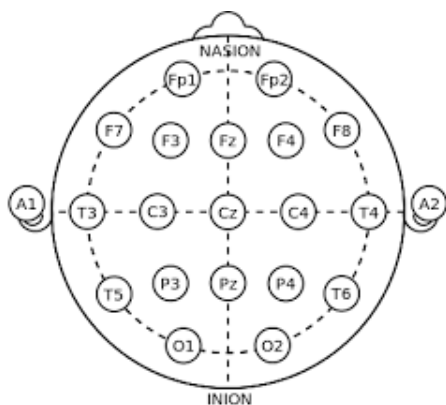
- Ο ρυθμός **Θ (Theta)** εμφανίζεται στις συχνότητες **4-8 Hz**. Παρατηρείται στην αφηρημάδα και τον ύπνο. Συνδέεται με την εμπειρία βαθέων συναισθημάτων, τη δημιουργικότητα και το βαθύ ύπνο. Όσο δεν παράγεται σε μεγάλο βαθμό, όταν κανείς είναι ξύπνιος, αποτελεί χρήσιμο ρυθμό. Υψηλή δραστηριότητα προκαλεί ADHD, κατάθλιψη, υπερδιέγερση, παρορμητικότητα, απροσεξία. Χαμηλή άγχος, φτωχή συναισθηματική συνείδηση. Ιδανικά προάγει τη δημιουργικότητα, συναισθηματική σύνδεση, χαλάρωση. Αύξηση οφείλεται σε αντικαταθλιπτικά.
- Ο ρυθμός **Δ (Delta)** εμφανίζεται στις συχνότητες **0-4 Hz**. Αποτελεί τον πιο αργό καταγεγραμμένο ρυθμό στον άνθρωπο. Παρατηρείται κυρίως σε βρέφη και μικρά παιδιά. Καθώς μεγαλώνουμε τείνουμε να παράγουμε όλο και λιγότερο delta ακόμα και στον ύπνο. Σχετίζεται με τον βαθύ και θεραπευτικό ύπνο, επίσης παρατηρήθηκε στις ακούσιες σωματικές λειτουργίες, όπως τη ρύθμιση του καρδιακού ρυθμού και της πέψης. Υψηλή δραστηριότητα προκαλεί εγκεφαλικές βλάβες, μαθησιακά προβλήματα, ανικανότητα σκέψης, σοβαρό ADHD. Χαμηλή αδυναμία ξεκούρασης του σώματος και του μυαλού, κακή ποιότητα ύπνου. Αύξηση παρατηρείται από αντικαταθλιπτικά και κατά τη διάρκεια του ύπνου.
- Η εγκεφαλική δραστηριότητα στο φλοιό του εγκεφάλου αλλάζει με την κίνηση ενός άκρου ή τη σύσπαση ενός μυ. Οι κύριοι εγκεφαλικοί ρυθμοί που σχετίζονται με την κίνηση είναι οι beta και μ ( $\mu$  **8-12 Hz**) [4], εμφανίζονται στην περιοχή του εγκεφαλικού φλοιού. Η κίνηση ή η προετοιμασία κίνησης συνοδεύεται από μείωση του πλάτους των beta, μ το φαινόμενο αυτό ονομάζεται αποσυντονισμός λόγω γεγονότος **ΑΔΓ (ERD event related desynchronazation)**. Αντίθετα αύξηση του πλάτους των mu, beta στα αρχικά επίπεδα των ονομάζεται συντονισμός λόγω γεγονότος **ΣΔΓ (ERS event related synchronazation)**. Συμβαίνει με την χαλάρωση που επέρχεται στο πέρας της πραγματοποιούμενης κίνησης [5]. Το βασικό πλεονέκτημα των ERD/ERS είναι η εμφανισή τους δεν απαιτεί την πραγματοποίηση κίνησης. Η σκέψη κίνησης (**MI motor imagery**) μόνο αρκεί, [6], [7].

### 1.1.1 Καταγραφή του ΗΕΓ: Το σύστημα 10-20

Το σύστημα 10-20 [8], [9], [10] είναι μια διεθνώς αναγνωρισμένη μέθοδος για την τοποθέτηση ηλεκτροδίων στην επιφάνεια του κεφαλιού για λήψη EEG σήματος από αυτή. Το 10-20 αναπτύχθηκε για να διασφαλίσει την ομογένεια των πειραμάτων ηλεκτροεγκεφαλογραφίας, ώστε η μελέτη που έγινε σε κάποιο υποκείμενο να μπορεί να συγκριθεί με μελλοντική, καθώς και με πειράματα που έγιναν σε διαφορετικούς ανθρώπους. Η βασική αρχή του 10-20 είναι η σχέση της τοποθεσίας ενός ηλεκτροδίου και του εγκεφαλικού φλοιού που βρίσκεται από κάτω του (ο οποίος εξειδικεύεται σε μια συγκεκριμένη ενέργεια π.χ. είναι υπεύθυνος για την κίνηση). Οι αριθμοί “10”-“20” αναφέρονται στις πραγματικές αποστάσεις των ηλεκτροδίων που είναι είτε 10% είτε 20% της συνολικής απόστασης από την μέση γραμμή (την διάμετρο που ορίζεται από την περιοχή πάνω από το τέλος της μύτης μέχρι το ινιακό οστό (το πίσω χαμηλότερο μέρος του κρανίου), ή τη διάμετρο που ορίζεται από το ευθύγραμμο τμήμα που ενώνει τους λοβούς των αυτιών.

Το 10-20 χωρίζει το κεφάλι σε 5 λοβούς, frontal, temporal, central, pariental, occipital που αναφέρονται με τα γράμματα F, T, C, P, O. Ακόμα τα γράμματα συνδυάζονται με

αριθμούς για την ονοματοθεσία κάθε ηλεκτροδίου. Οι άρτιοι αριθμοί 2, 4, 6, 8 αριθμούν ηλεκτρόδια του δεξιού ημισφαιρίου και οι περιττοί 1, 3, 5, 7 του αριστερού. Τα ηλεκτρόδια που αναφέρονται με ένα από τα πέντε γράμματα και το γράμμα z(zero) βρίσκονται στο κέντρο του εγκεφάλου (τη διάμετρο μύτης ινιακού οστού). Ακόμα οι κωδικοί γραμμάτων A, P, F, δίνουν τις θέσεις των ηλεκτροδίων που τοποθετούνται στους λοβούς των αυτιών, την ρινοφαρυγγική περιοχή και τους κροτάφους πάνω από τα μάτια.



Εικόνα1 : Αναπαράσταση 10-20, [commons.wikimedia.org]

## 1.2 Διεπαφή εγκεφάλου υπολογιστή

Ο ανθρώπινος εγκέφαλος είναι ένα περίπλοκο σύστημα και η σημερινή τεχνολογία προσπαθεί να βρει τρόπους άντλησης πληροφοριών από το EEG, για την ανάπτυξη εφαρμογών που καθοδηγούνται από τη σκέψη του χρήστη. Σκοπός είναι να αναπτυχθούν εφαρμογές που μεταφράζουν τη πρόθεση του ατόμου σε εντολή υπολογιστή. Αυτό το σκοπό εξυπηρετεί η διεπαφή εγκεφάλου-υπολογιστή (BCI brain computer interface) [11], [12].

Ένα σύστημα BCI μπορεί να προσφέρει ένα μέσο επικοινωνίας και ελέγχου, χωρίς μυική κίνηση. Μπορεί να αποτελέσει νέο μονοπάτι επικοινωνίας σε άτομα με σοβαρά κινητικά προβλήματα. Τα BCI συστήματα μπορούν να εφαρμοστούν στην χρήση ρομποτικών άκρων, αναπηρικών αμαξιδίων, εγγραφή μηνυμάτων σε οθόνη (P300 speller) [13], καθώς και για ψυχαγωγικό σκοπό ως μέσο επικοινωνίας χρήστη-βιντεοπαιχνιδιού.

## 1.3 Εμπορικά διαθέσιμα EEG προϊόντα.

Υπάρχουν διάφορες συσκευές καταγραφής EEG στην αγορά. Μερικά χαρακτηριστικά παραδείγματα είναι τα παρακάτω:

- Neurosky headset

Η neurosky παρέχει 2 κατηγορίες wearable EEG headset. Το Mindwave σχεδιασμένο για PC, Mac και το Mindwave Mobile για PC, Mac, smartphone. Το headset μπορεί να χρησιμοποιηθεί για εκπαιδευτικούς σκοπούς, διασκέδαση, ευεξία. Διαθέτει 3 κανάλια (ξηρά ηλεκτρόδια, δεν χρειάζονται αγωγίμο gel ή αλατούχο διάλυμα). Ένα κανάλι καταγραφής EEG, ένα αναφοράς και μια γείωση. Η λήψη του σήματος γίνεται

με συχνότητα δειγματοληψίας 512Hz, η συσκευή συνδέεται ασύρματα με τον υπολογιστή [14], [15].

- Open BCI 32bit Board

Μπορεί να χρησιμοποιηθεί για λήψη EEG, ηλεκτρομυογραφήματος (EMG - ΗΜΓ), ηλεκτροκαρδιογραφήματος (ΗΚΓ - ECG).

Διαθέτει 8 κανάλια καταγραφής, επιταχυνσίόμετρο, υποδοχή κάρτας MicroSD. Συνδέεται ασύρματα με Η/Υ, tablet, smartphone με bluetooth usb dongle [16].

- Emotiv epoc headset

Μπορεί να χρησιμοποιηθεί για εκπαιδευτικούς, ψυχαγωγικούς, ερευνητικούς σκοπούς. Διαθέτει 14 κανάλια καταγραφής EEG (υγρά ηλεκτρόδια χρειάζονται αγωγίμο αλατούχο διάλυμα) και 2 κανάλια αναφοράς. Η συχνότητα δειγματοληψίας είναι 128 Hz. Επικοινωνεί με τον Η/Υ (PC, Mac, Linux) με ασύρματο bluetooth usb dongle. Το emotiv παρέχει διάφορα προγράμματα για την χρήση του headset δωρεάν ή μη ανάλογα με την χρήση που επιθυμεί κανείς [17], [18], [19].

## 1.4 Μέθοδοι εξαγωγής χαρακτηριστικών για BCI motor imagery

### 1.4.1 Ο μετασχηματισμός wavelet

Τα EEG σήματα είναι μη στατικά έτσι μέθοδοι που εστιάζουν στο πεδίο χρόνου-συχνότητας είναι αποτελεσματικότερες για την μελέτη τους [20].

Ο μετασχηματισμός wavelet (wavelet transform) [21] είναι μια τεχνική εκτίμησης του φάσματος ενός σήματος. Με τον wavelet transform κάθε σήμα μπορεί να εκφραστεί ως συνδυασμός συναρτήσεων wavelet [22]. Τα wavelets προκύπτουν από τη διαστολή και μετατόπιση μιας συγκεκριμένης συνάρτησης (mother wavelet). Το αρχικό σήμα μπορεί να ανακατασκευαστεί με τον αντίστροφο μετασχηματισμό wavelet, από το mother wavelet σταθμισμένο από τον γραμμικό συνδυασμό των wavelet coefficients. Για την σωστή ανακατασκευή του αρχικού σήματος πρέπει προηγουμένως να έχει υπολογιστεί ο σωστός αριθμός wavelet coefficients. Το στοιχείο κλειδί του μετασχηματισμού wavelet, είναι ότι αποτυπώνει τη συχνότητα του σήματος αλλά και τοπικές πληροφορίες του που μεταβάλλονται με το χρόνο [23]. Η ενέργεια κάθε συνιστώσας περιορίζεται σε ένα συγκεκριμένο χρονικό παράθυρο. Ακόμα γίνεται “τοπικοποίηση” της συχνότητας με την έννοια ότι οι wavelet coefficients χωρίζουν το συχνοτικό περιεχόμενο του προς μελέτη σήματος σε διακριτές ζώνες. Αυτή η τμηματοποίηση του χρόνου-συχνότητας που δημιουργεί ο μετασχηματισμός wavelet είναι κατάλληλη για την μελέτη σημάτων που είναι ασταθή και η συχνότητά τους μεταβάλλεται συνεχώς με το χρόνο, όπως συμβαίνει με τα EEG σήματα.

Κατηγορίες του μετασχηματισμού wavelet:

Συνεχής μετασχηματισμός wavelet (CWT continuous wavelet transform). Χρησιμοποιείται στην τμηματοποίηση ενός συνεχούς χρονικού σήματος σε επιμέρους wavelets. Η μαθηματική έκφραση του CWT [24]:

$$\gamma(s, \tau) = \int f(t) \psi_{s, \tau}^*(t) dt \quad (1)$$

Το σήμα στο πεδίο του χρόνου  $f(t)$ , συνελλίσεται με την συνάρτηση mother wavelet  $\psi_s$  και δίνει τις wavelet coefficients  $\gamma$ . Οι μεταβλητές  $s, \tau$  καθορίζουν τη διαστολή και

τη μετατόπιση αντίστοιχα. Η μαθηματική έκφραση του μητρικού wavelet για CWT[24]:

$$\psi_{s,\tau} = \frac{1}{\sqrt{s}} \psi\left(\frac{t-\tau}{s}\right) \quad (2)$$

Διακριτός μετασχηματισμός wavelet (Discrete Wavelet Transform-DWT). Χρησιμοποιείται στην τμηματοποίηση ενός χρονικού διακριτού σήματος (ψηφιοποιημένου). Η μαθηματική του έκφραση είναι [24]:

$$\psi_{j,k}(t) = \frac{1}{\sqrt{s_o^j}} \psi\left(\frac{t - k\tau_o s_o^j}{s_o^j}\right) \quad (3)$$

Οι δείκτες  $j, k$  είναι ακέραιοι και το  $s_o > 1$  είναι σταθερό και εκφράζει τη διαστολή. Ο παράγοντας μετατόπισης  $\tau_o$  εξαρτάται από το  $s_o$ . Το αποτέλεσμα του DWT είναι η κλίμακα του χρόνου τώρα έχει δειγματοληπτηθεί σε διακριτά διαστήματα. Συνήθως διαλέγεται  $s_o=2$ , ώστε ο δειγματισμός του άξονα της συχνότητας να ανταποκρίνεται σε δυαδική δειγματοληψία (επιλέγεται μέγεθος ψηφιακού σήματος με άρτιο αριθμό σημείων). Αυτό αποτελεί μια πολύ φυσική επιλογή για τους υπολογιστές. Η τιμή  $\tau_o=1$  επιλέγεται συνήθως, ώστε να υπάρχει δυαδική δειγματοληψία και στον άξονα του χρόνου.

Ο μετασχηματισμός wavelet χωρίζει το σήμα σε  $N$  επίπεδα από συνιστώσες (coefficients), που χωρίζονται σε λεπτομέρειες (details) και προσεγγίσεις (approximations). Ο διαχωρισμός του σήματος από τον DWT γίνεται αρχικά με εφαρμογή χαμηλοπερατού, έπειτα υψηροπερατού φίλτρου που δίνει το πρώτο επίπεδο διαχωρισμού με ένα coefficient approximation και ένα coefficient detail. Τα detail δημιουργούνται από το υψηροπερατό φίλτρο και τα approximation από το χαμηλοπερατό. Αν το σήμα αποτελείται από  $X$  σημεία, τότε το coefficient approximation και το coefficient detail αποτελούνται έκαστα από  $X/2$ . Στη συνέχεια το coefficient approximation φιλτράρεται πάλι από χαμηλοπερατό και υψηροπερατό φίλτρο και δίνει το νέο επίπεδο coefficient approximation και coefficient detail. Η διαδικασία διαδοχικού φιλτραρίσματος των coefficient approximation συνεχίζεται μέχρι να καληφθούν τα  $N$  επίπεδα του wavelet transform. Αφού υπολογιστούν τα coefficients, ένας αλγόριθμος ανακατασκευής δίνει τα approximation και τα detail όλων των επιπέδων που αποτελούνται από  $N$  σημεία όπως το αρχικό σήμα. Τα detail και approximation ονομάζονται wavelets. Για την αναδημιουργία του αρχικού σήματος ο αντίστροφος wavelet transform χρησιμοποιεί τα wavelets του τελευταίου επιπέδου και τα details των προηγούμενων επιπέδων. Το ανακατασκευασμένο σήμα πλησιάζει σχεδόν άριστα το αρχικό [23]. Ο μετασχηματισμός wavelet χωρίζει το EEG στον κατάλληλο αριθμό επιπέδων και αποδίδει τους βασικούς ρυθμούς του εγκεφάλου. Στη συνέχεια επιλέγονται τα κατάλληλα wavelet coefficient που περιέχουν τους ρυθμούς  $\mu$ ,  $\beta$  για motor imagery. Από τα wavelet αυτά εξάγονται features όπως η μέση, μέγιστη τιμή, τυπική απόκλιση [25], [26].

## 1.5 Αλγόριθμοι ταξινόμησης

Σκοπός ενός BCI είναι να μεταφράσει την εγκεφαλική δραστηριότητα σε εντολή υπολογιστή. Για να γίνει αυτό πρέπει να χρησιμοποιηθεί ένας αλγόριθμος ταξινόμησης για να αναγνωρίσει δεδομένα με παρόμοια ή διαφορετικά χαρακτηριστικά [27].

### 1.5.1 Γραμμικοί ταξινομητές (Linear Classifiers)

- Ο αλγόριθμος Linear Discriminant Analysis (LDA) στοχεύει με τη χρήση υπερεπιπέδων να διαχωρίσει τα δεδομένα που ανήκουν σε διαφορετική κλάση. Το υπερεπίπεδο αναπαριστάται με συνάρτηση ευθείας. Σε ένα παράδειγμα ταξινόμησης 2 κλάσεων, η κλάση ενός feature vector (διανύσματος χαρακτηριστικών) που αναπαρίσταται ως σημείο εξαρτάται σε ποια πλευρά του υπερεπιπέδου βρίσκεται. Ο αλγόριθμος θεωρεί την μια κλάση θετική και την άλλη αρνητική. Στην θετική κλάση ταξινομούνται τα σημεία, που όταν δίνονται στην συνάρτηση του υπερεπιπέδου το αποτέλεσμα είναι θετικό, στην αντίθετη περίπτωση το σημείο ταξινομείται στην αρνητική κλάση. Η ίδια λογική μπορεί να επεκταθεί στην ταξινόμηση περισσότερων κλάσεων. Ο LDA υποθέτει ότι τα δεδομένα ακολουθούν κανονική κατανομή. Ο αλγόριθμος αναζητά το ιδανικό υπερεπίπεδο, που μεγιστοποιεί την απόσταση των κλάσεων και ελαχιστοποιεί την διακύμανση μέσα στην ίδια κλάση. Για την επίλυση προβλήματος  $N$  κλάσεων ( $N > 2$ ) αρκετά υπερεπίπεδα χρησιμοποιούνται. Ο LDA έχει χαμηλή υπολογιστική πολυπλοκότητα που τον καθιστά ιδανικό για online BCI εφαρμογές [28], [29].
- Ο αλγόριθμος Support Vector Machine (SVM) επίσης χρησιμοποιεί υπερεπίπεδα για να διαχωρίσει τις κλάσεις. Προσπαθεί να ξεχωρίσει τα feature vectors (σημεία) που ανήκουν σε διαφορετικές αφήνοντας το μεγαλύτερο δυνατό κενό μεταξύ των κλάσεων. Τα σημεία που βρίσκονται στη μικρότερη απόσταση από την ευθεία του υπερεπιπέδου, που διαχωρίζει τις 2 κλάσεις είναι τα support vectors. Αυτή η περίπτωση που είναι γνωστή ως linear SVM. Ακόμα υπάρχει η δυνατότητα χρήσης μη γραμμικής συνάρτησης υπολογισμού υπερεπιπέδου. Ο SVM αποτελεί δημοφιλή αλγόριθμο ταξινόμησης EEG [30], [31].

### 1.5.2 Νευρωνικά Δίκτυα (Neural Networks - Multilayer Perceptron)

Πολυεπίπεδα νευρωνικά δίκτυα Perceptron (Multilayer Perceptron Neural Networks).

Η δομική μονάδα είναι ο νευρώνας. Είναι μια συνάρτηση που παρομοιάζεται με τον βιολογικό νευρώνα. Έχει 1 ή περισσότερες εισόδους (κόμβους) που πολλαπλασιάζεται κάθε μια ξεχωριστά με την ίδια ή διαφορετική τιμή, το βάρος. Το άθροισμα των κόμβων δίνεται ως είσοδος στην συνάρτηση ενεργοποίησης που είναι ουσιαστικά ο νευρώνας. Αν το άθροισμα των κόμβων ξεπερνά το κατώφλι (ελάχιστη απαιτούμενη τιμή) της συνάρτησης ενεργοποίησης τότε ο νευρώνας παράγει έξοδο. Ο στοιχειώδης νευρώνας ονομάζεται perceptron. Στην περίπτωση που συνδυάζονται πολλοί νευρώνες τότε δημιουργείται ένα multilayer perceptron neural network (MLP). Το MLP αποτελείται από διαφορετικά επίπεδα νευρώνων, ένα επίπεδο εισόδου (input layer), ένα ή περισσότερα κρυφά επίπεδα (hidden layer), και το επίπεδο εξόδου (output layer). Η είσοδος κάθε νευρώνα συνδέεται με την έξοδο κάθε νευρώνα του προηγούμενου επιπέδου. Οι νευρώνες του output layer καθορίζουν την κλάση του feature vector που δόθηκε ως είσοδος στο δίκτυο [25].

### 1.5.3 Ταξινομητές κοντινότερου γείτονα

Σκοπός του αλγορίθμου κ κοντινότερων γειτόνων (K Nearest Neighbours) είναι να προσδιορίσει την κλάση του σημείου (feature vector) βάση της κλάσης του



κοντινότερου γειτονικού σημείου, ανάμεσα στους  $k$  γείτονές του. Η απόσταση υπολογίζεται με αλγόριθμο που υλοποιεί μια μετρική απόστασης π.χ την ευκλείδεια απόσταση. Ο  $k$ -NN θεωρείται κατάλληλος για ταξινόμηση EEG feature vectors με μικρό αριθμό χαρακτηριστικών [32].

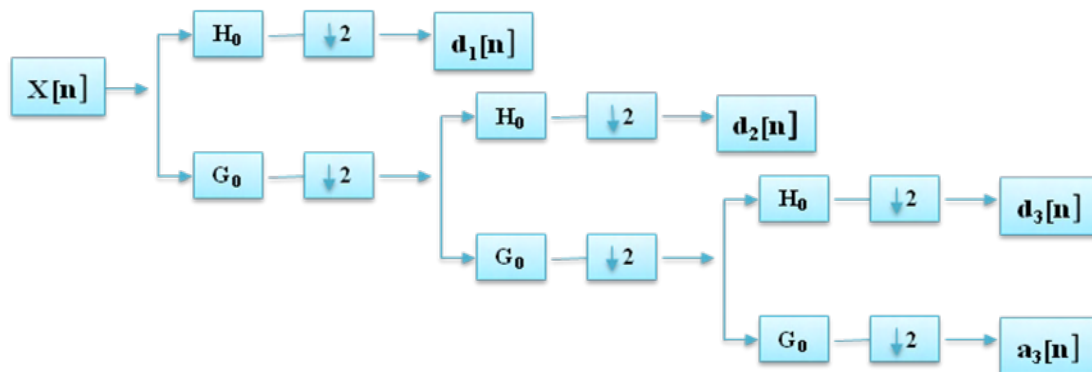
## 2 Μεθοδολογία

### 2.1 Μέθοδος εξαγωγής χαρακτηριστικών στην παρούσα εργασία

Για την εξαγωγή χαρακτηριστικών (feature extraction) έγινε χρήση του διακριτού μετασχηματισμού wavelet (DWT) και ζωνοπερατών φίλτρων IIR (infinite impulse response) chebychev type II με την βοήθεια των wavelet toolbox και filter toolbox της matlab.

#### 2.1.1 Χαρακτηριστικά βασισμένα σε διακριτό μετασχηματισμό wavelet

Τα EEG σήματα που περιγράφονται στις ενότητες 3.1, 3.2 έχουν ληφθεί με συχνότητα δειγματοληψίας  $f_s=128\text{Hz}$ . Από το θεώρημα δειγματοληψίας του Nyquist [33] προκύπτει ότι η μέγιστη χρήσιμη συχνότητα που περιέχεται στο δειγματοληπτημένο σήμα είναι η μισή της συχνότητας δειγματοληψίας ( $f_s$ )  $f_{\max} = f_s / 2$ , δηλαδή 64 Hz. Έτσι ο DWT χωρίζει τα EEG σήματα σε  $N=4$  επίπεδα από wavelets (wavelet coefficients). Οι συνιστώσες που περιέχουν τους βασικούς ρυθμούς του EEG φαίνονται στον Πίνακα (1).



**Εικόνα 2.** Ο μετασχηματισμός DWT 3 επιπέδων ενός διακριτού σήματος. Το διακριτό σήμα  $x(n)$  αρχικά διέρχεται διαδοχικά από χαμηλοπερατό, υψηλοπερατό φίλτρο και χωρίζεται στα coefficient approximation, detail (πρώτου επιπέδου) αντίστοιχα με  $n/2$  σημεία το καθένα. Στη συνέχεια το detail φιλτράρεται ξανά διαδοχικά και δίνει το δεύτερο επίπεδο coefficient detail, approximation.

**Πίνακας 1.** Ο μετασχηματισμός wavelet 4 επιπέδων για EEG με συχνότητα  $f_s = 128Hz$

Ζώνες συχνοτήτων (Hz)	Wavelet coefficients
0-4	A4 (Approximation 4)
4-8	D4 (Detail 4)
8-16	D3 (Detail 3)
16-32	D2 (Detail 2)
32-64	D1 (Detail 1)

Από τις παραπάνω συνιστώσες, οι Detail2, Detail3 περιέχουν τους ρυθμούς MI (motor imagery)  $\mu(8-12)$ ,  $\beta(16-32)$ , κατά συνέπεια επιλέγονται για την εξαγωγή χαρακτηριστικών. Τα χαρακτηριστικά που προκύπτουν στην παρούσα εργασία από την εφαρμογή των παρακάτω συναρτήσεων στα Detail2, Detail3 [34], [25], [6] είναι:

- η μέση τιμή (mean)
- μέγιστη τιμή (max)
- τυπική απόκλιση (standard deviation),
- νόρμα 1 (norm 1)
- νόρμα 2 (norm 2)
- νόρμα άπειρο (infinite norm)
- το εύρος τιμών (max value-min value ,range)
- η συχνότερα εμφανιζόμενη τιμή (mode)
- μέγιστη απόλυτη τιμή πλάτους (mean(abs))

Ο DWT εφαρμόζεται με τις συναρτήσεις mother wavelet:

- daubechies 2
- daubechies 4
- coiflet 2
- coiflet 4
- symlet 2
- symlet 4

## 2.1.2 Χαρακτηριστικά βασισμένα σε φίλτρα IIR Chebychev type II

Τα EEG προς μελέτη σήματα φιλτράρονται στις ζώνες των ρυθμών mu(8-12Hz), beta(18-26Hz) με δυο ξεχωριστά ζωνοπερατά φίλτρα, με τα ακόλουθα χαρακτηριστικά:

- ζώνη διέλευσης [8-12Hz], ζώνη αποκοπής [7-19Hz] για το ρυθμό  $\mu$
- ζώνη διέλευσης [18-26Hz], ζώνη αποκοπής [10-30Hz] για το ρυθμό  $\beta$
- απορρόφηση ισχύος εκτός της ζώνης διέλευσης ίση με 50db
- μέγιστη διακύμανση στη ζώνη διέλευσης 3dB

Η τάξη του φίλτρου για αμφοτέρους τους ρυθμούς beta και mu βρέθηκε  $n=6$ . Οι συντελεστές της γραμμικής εξίσωσης διαφορών (ΓΕΔ) για κάθε ένα από τα 2 φίλτρα Chebychev δίνονται στον Πίνακα (2).

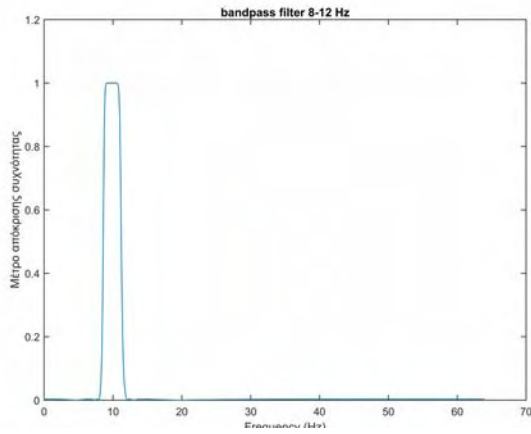
Η συνάρτηση μεταφοράς για τα δύο φίλτρα αν όπου  $\alpha$ ,  $\beta$  βάλουμε τις τιμές του Πίνακα (2) δίνονται από τη Σχέση (4)

$$H_1(z) = \frac{\sum_{k=0}^{12} \beta_k z^{-k}}{1 - \sum_{k=0}^{12} \alpha_k z^{-k}} \quad (4)$$

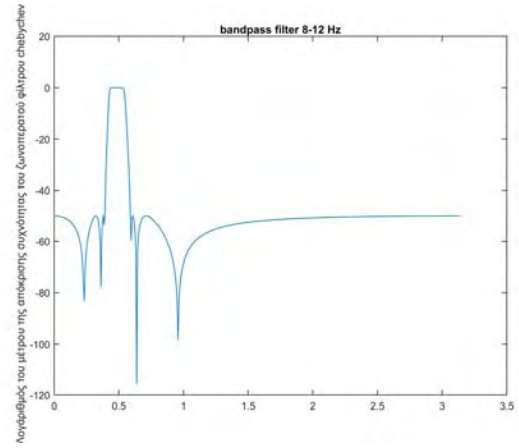
**Πίνακας 2.** Οι συντελεστές της γραμμικής εξίσωσης διαφορών (ΓΕΔ) για κάθε ένα από τα 2 φίλτρα chebychev, σύμφωνα με την σχέση (4).

K	Ζωνοπερατό φίλτρο chebychev 18-26Hz		Ζωνοπερατό φίλτρο chebychev 8-12Hz	
	$\alpha_k$	$\beta_k$	$\alpha_k$	$\beta_k$
0	1.0000	0.0034	1.0000	0.0029
1	-5.2858	-0.0165	-10.1926	-0.0293
2	16.6559	0.0481	48.8037	0.1399
3	-35.8162	-0.0984	-144.9119	-0.4179
4	58.6737	0.1584	296.8578	0.8698
5	-75.0047	-0.2069	-441.6884	-1.3282
6	77.0697	0.2262	489.2444	1.5257
7	-63.4381	-0.2069	-406.4461	-1.3282
8	41.9704	0.1584	251.3753	0.8698
9	-21.6644	-0.0984	-112.9187	-0.4179
10	8.5185	0.0481	34.9949	0.1399

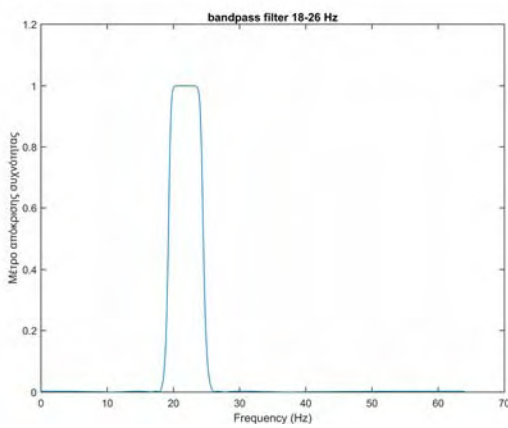
11	-2.2851	-0.0165	-6.7256	-0.0293
12	0.3657	0.0034	0.6072	0.0029



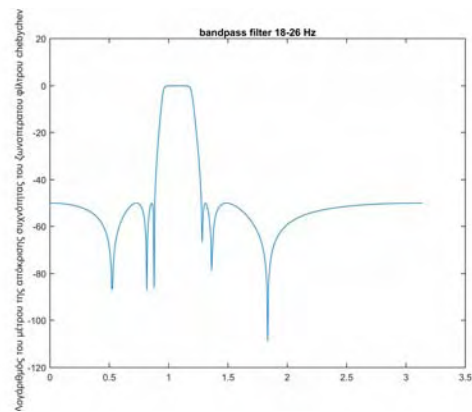
(α)



(β)



(γ)

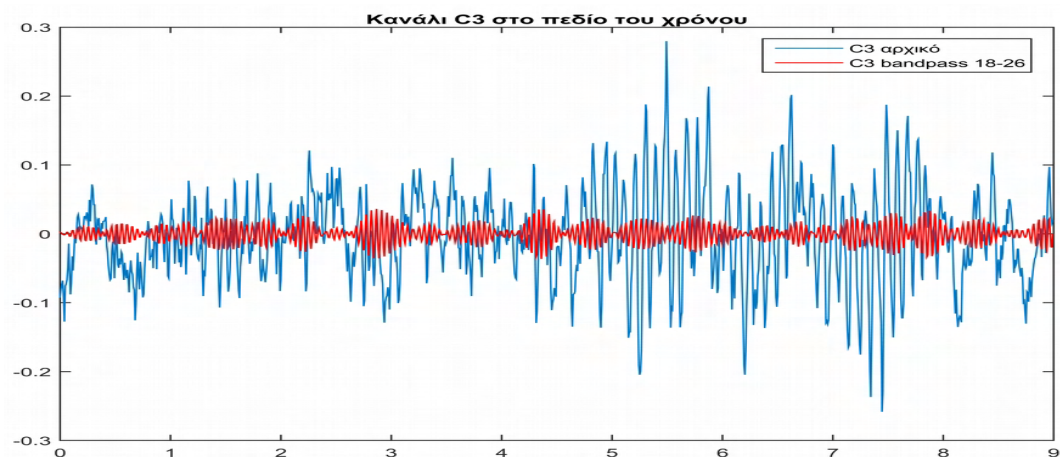


(δ)

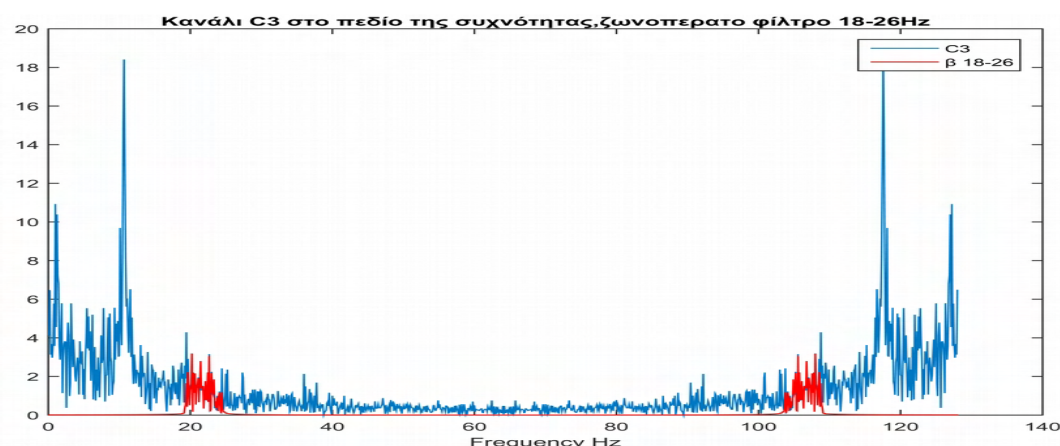
**Εικόνα (3)**

Το μέτρο της απόκρισης συχνότητας για το ζωνοπερατά φίλτρα Chebyshev (8-12Hz), (18-26Hz) δίνεται από τη Σχέση (4) και φαίνονται στις Εικόνες 3(α), (γ). Οι εικόνες (3β), (3δ), δείχνουν τον λογάριθμο του μέτρου της απόκρισης των ζωνοπερατών φίλτρων Chebyshev (8-12Hz), (18-26). Παρατηρείται ότι ικανοποιείται η απαίτηση για απορρόφηση 50dB στις ζώνες αποκοπής.

Η Εικόνα 4(α) δείχνει το κανάλι C3 από το δεύτερο πείραμα του train dataset του BCI Competition dataset (Κεφάλαιο 3 παράγραφος 3.2) στο πεδίο του χρόνου μαζί με το φιλτραρισμένο σήμα από το Chebychev (18-26Hz) και αντιστοιχεί σε MI δεξιού χεριού. Το φάσμα Fourier του αρχικού C3 και του φιλτραρισμένου κατά Chebychev C3 φαίνεται στην εικόνα 4(β).



(α)



(β)

**Εικόνα 4. α)** κανάλι C3 από το δεύτερο πείραμα του dataset  $x_{train}$  του BCI Competition II dataset III (MI δεξιού χεριού) μαζί με το φιλτραρισμένο σήμα του από το chebychev (18-26Hz) στο πεδίο του χρόνου, **β)** φάσμα Fourier του αρχικού C3 και του φιλτραρισμένου κατά Chebychev C3.

## 2.2 Αλγόριθμοι ταξινόμησης που χρησιμοποιήθηκαν

Στα feature vectors που προέκυψαν σύμφωνα με τα 2.1.1, 2.2.2 εφαρμόστηκαν οι αλγόριθμοι ταξινόμησης LDA, SVM, k-NN και νευρωνικά δίκτυα ενός κρυφού επιπέδου με 10 και 15 κρυφούς νευρώνες. Η υλοποίηση των αλγορίθμων έγινε με το matlab classification toolbox.

Για κάθε διαφορετικό διάνυσμα χαρακτηριστικών (feature vector) που ταξινομήθηκε με τους LDA, SVM, k-NN, δεσμεύτηκε με τυχαίο τρόπο το 50% των δεδομένων του

πίνακα για εκπαίδευση του αλγορίθμου ταξινόμησης και το υπόλοιπο 50% δόθηκε ως test set για την μέτρηση της ακρίβειας ταξινόμησης.

### 2.2.1 Linear discriminant analysis

Το matlab παρέχει τις παρακάτω συναρτήσεις υπολογισμού υπερεπιπέδου για τον διαχωρισμό κλάσεων [35], Πίνακας (3).

Πίνακας 3

Συνάρτηση matlab	Περιγραφή	Πίνακας συνδιακύμανσης του ταξινομητή
linear	LDA	Όλες οι κλάσεις έχουν τον ίδιο πίνακα συνδιακύμανσης
diaglinear	LDA	Οι κλάσεις έχουν τον ίδιο διαγώνιοπίνακα συνδιακύμανσης
pseudolinear	LDA	Όλες οι κλάσεις έχουν τον ίδιο πίνακα συνδιακύμανσης. Το λογισμικό αναστρέφει το πίνακα συνδιακύμανσης
quadratic	Quadratic discriminant analysis (QDA)	Οι πίνακες συνδιακύμανσης μπορούν να διαφέρουν μεταξύ διαφορετικών κλάσεων
diagquadratic	QDA	Οι πίνακες συνδιακύμανσης είναι διαγώνιοι και μπορούν να διαφέρουν μεταξύ των κλάσεων
pseudoquadratic	QDA	Οι πίνακες διακύμανσης μπορούν να διαφέρουν μεταξύ των κλάσεων. Το λογισμικό αναστρέφει το πίνακα διακύμανσης.

### 2.2.2 Support vector machine

Για την εφαρμογή του ταξινομητή SVM χρησιμοποιήθηκε το σχετικό Toolbox του Matlab. Ο ταξινομητής SVM χρησιμοποιεί διάφορες συναρτήσεις για το υπερεπίπεδο που διαχωρίζει τις κλάσεις. Οι συναρτήσεις που υποστηρίζει το matlab [36], δοκιμάστηκαν στην παρούσα πτυχιακή και δίνονται στον Πίνακα (4).

**Πίνακας 4.** Συναρτήσεις υπολογισμού της απόστασης μεταξύ δυο διανυσμάτων χαρακτηριστικών

Συνάρτηση matlab	Περιγραφή	Μαθηματική έκφραση
gaussian or rbf	Gaussian ή Radial Basis Function (RBF). Εξ' ορισμού συνάρτηση για την εκμάθηση μιας κλάσης.	$G(x_1, x_2) = e^{-\ x_1 - x_2\ ^2}$
linear	Εξ' ορισμού συνάρτηση για την εκμάθηση 2 κλάσεων	$G(x_1, x_2) = x_1' x_2$
polynomial		$G(x_1, x_2) = (1 + x_1' x_2)^p$

### 2.2.3 k nearest neighbor

Ο k-NN χρησιμοποιήθηκε για κάθε feature vector. Για κάθε μετρική της απόστασης επιλέχθηκε η βέλτιστη τιμή της παραμέτρου k (αριθμός γειτόνων) σε ακτίνα τιμών [1,20], ως η τιμή που επιτυγχάνει το μικρότερο σφάλμα ταξινόμησης στο Feature Vector 1 και 2 με 10 fold cross-validation.

Το matlab παρέχει τις παρακάτω συναρτήσεις υπολογισμού της απόστασης [37] Πίνακας(5)

**Πίνακας 5.** Συναρτήσεις υπολογισμού της απόστασης μεταξύ δυο διανυσμάτων χαρακτηριστικών  $p, q$  διάστασης  $n$ .

Συνάρτηση matlab για υπολογισμό απόστασης	Περιγραφή
Cityblock	$d(p, q) = \sum_{i=1}^n (p_i - q_i)$
Chebyshev	$d(p, q) = \max(\{ p_i - q_i , i = 1, 2, \dots, n\})$
Correlation	Ένα μείον το δείγμα της γραμμικής συσχέτισης μεταξύ των διανυσμάτων
Cosine	Ένα μείον το συνημίτονο της γωνίας μεταξύ των διανυσμάτων
Euclidean	$d(p, q) = \sqrt{(q_1 - p_1)^2 + (q_2 - p_2)^2 + \dots + (q_n - p_n)^2}$
Hamming	Ο αριθμός των αντικαταστάσεων που χρειάζεται για να μετατραπεί το ένα διάνυσμα στο άλλο

Jaccard	Ένα μείον το ποσοστό των μη μηδενικών συντεταγμένων των διανυσμάτων που διαφέρουν μεταξύ τους.
mahalanobis	Μετρά την ανομοιότητα δυο διανυσμάτων χαρακτηριστικών της ίδιας κατανομής με πίνακα διακύμανσης $S$ . $d(p, q) = \sqrt{(p - q)^T S^{-1} (p - q)}$
Minkowski	$d(p, q) = \left( \sum_{i=1}^n  p_i - q_i ^p \right)^{\frac{1}{p}}$
Euclidean	Ευκλείδεια απόσταση χαρακτηριστικών κανονικοποιημένων με την τυπική απόκλιση των τιμών τους.
Spearman	Ένα μείον τη συσχέτιση Spearman's μεταξύ των $p$ και $q$ .

## 2.2.4 Artificial Neural Networks-Multilayer Perceptron

Για την ταξινόμηση με χρήση ANN, κάθε πίνακας χαρακτηριστικών (feature table) χωρίζεται σε 3 τμήματα. Το 70% των δεδομένων χρησιμοποιείται για την εκπαίδευση (train) του νευρωνικού δικτύου, το 15% για έλεγχο και προσαρμογή (validation) του δικτύου κατά τη διάρκεια της εκπαίδευσης και το 15% για δοκιμή του ταξινομητή (train) μετά το τέλος της εκπαίδευσης [38].

**Πίνακας 6.** Αλγόριθμοι των συναρτήσεων εκπαίδευσης του matlab

Αλγόριθμος	Συνάρτηση matlab
BFGS Quasi-Newton	trainbfg
Resilient Backpropagation	trainrp
Scaled Conjugate Gradient	trainscg
Conjugate Gradient with Powell/Beale Restarts	traincgb
Fletcher-Powell Conjugate Gradient	traincgf
Polak-Ribière Conjugate Gradient	traincgp
One Step Secant	trainoss



Variable Learning Rate Backpropagation	traingdx
Bayesian regularization backpropagation	trainbr

### 2.3 Ποσοτικοποίηση της ακρίβειας της ταξινόμησης

Μετά την εφαρμογή οποιουδήποτε ταξινομητή είναι απαραίτητο να υπολογισθεί η ακρίβεια με την οποία καταχωρεί τα δεδομένα στην σωστή κλάση. Στην παρούσα εργασία η ακρίβεια ταξινόμησης (classification accuracy) υπολογίζεται με τον confusion matrix. Κάθε γραμμή του πίνακα αναπαριστά την ετικέτα κλάσης (class1,class2,...), ενώ κάθε στήλη την προβλεπόμενη κλάση των στοιχείων που επεξεργάζονται από τον ταξινομητή. Ο confusion matrix είναι πίνακας 2x2. Η ετικέτα της πρώτης γραμμής ονομάζεται θετική κλάση (condition positive) και της δεύτερης αρνητική (condition negative). Οι στήλες περιέχουν το άθροισμα των στοιχείων που ο ταξινομητής προσδιορίζει στην class1 ή class2. Τα διαγώνια στοιχεία του confusion matrix ονομάζονται αντίστοιχα true positive, true negative και αντιπροσωπεύουν τα σωστά ταξινομημένα στοιχεία. Το άθροισμα των στοιχείων που ταξινομούνται στη θετική κλάση χωρίς να ανήκουν σε αυτή ονομάζονται false negative, αντίστοιχα το άθροισμα των ταξινομούμενων από λάθος στην αρνητική κλάση ονομάζονται false positive. Η ακρίβεια της ταξινόμησης (classification accuracy) είναι το άθροισμα των true positive, true negative προς το συνολικό αριθμό των στοιχείων που δόθηκαν ως είσοδο στον ταξινομητή.

$$accuracy = \frac{TP + TN}{TP + TN + FP + FN} \quad (5)$$

Πίνακας 7 : Confusion matrix

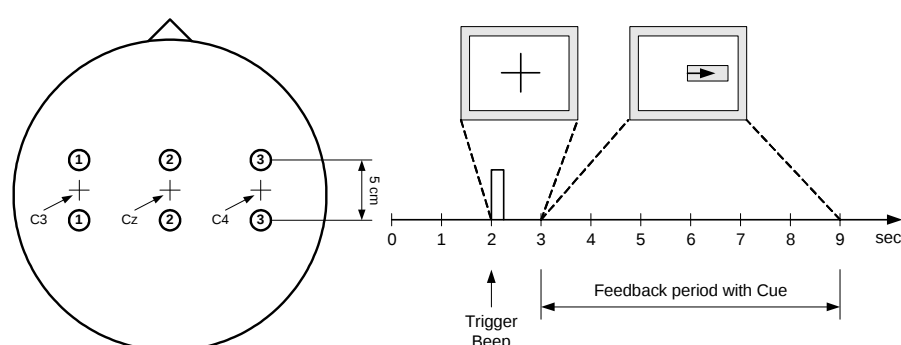
	Προβλεπόμενη κλάση	
Πραγματική κλάση	Δεξιά	Αριστερά
Δεξιά	True positive (TP)	False negative (FN)
Αριστερά	False positive (FP)	True negative (TN)

### 3 Δεδομένα που χρησιμοποιήθηκαν

Διάφορες ερευνητικές ομάδες και πανεπιστήμια καταγράφουν πειράματα BCI και δημοσιεύουν τα EEG datasets για την διεξαγωγή διαγωνισμών, στους οποίους συμμετέχουν ομάδες από όλο τον κόσμο με σκοπό να βρεθούν νέοι τρόποι επεξεργασίας και ταξινόμησης EEG. Χαρακτηριστικό παραδείγματα είναι το Institute for Biomedical Engineering, University of Technology Graz [39] που διοργανώνει διαγωνισμούς επεξεργασίας EEG με διάφορα θέματα όπως motor imagery [40], P300 speller [41]. Συνολικά έχει πραγματοποιήσει 4 διαγωνισμούς [42]. Άλλες πηγές για EEG datasets: [43], [44], [45].

#### 3.1 Έτοιμα δεδομένα EEG που χρησιμοποιήθηκαν

Το έτοιμο dataset που χρησιμοποιήθηκε είναι το datasetIII (BCI Competition II)[46]. Καταγράφηκε από υγιές άτομο (γυναίκα) 25 ετών, που κατά τη διάρκεια της διαδικασίας καθόταν σε αναπαυτική καρέκλα με μπράτσα. Σκοπός του πειράματος ήταν το άτομο να ελέγξει μια μπάρα που εμφανιζόταν στην οθόνη υπολογιστή με MI (motor imagery) δεξιού/αριστερού χεριού. Η σειρά των εντολών για πραγματοποίηση κίνησης ήταν τυχαία. Το πείραμα αποτελείται από 7 επαναλήψεις με 40 δοκιμές η κάθε μια. Όλα τα πειράματα έγιναν την ίδια μέρα με αρκετά λεπτά διάλλειμα μεταξύ τους. Οι 280 δοκιμές που εκτελέστηκαν διήρκεσαν 9sec η κάθε μια. Τα πρώτα 2sec της δοκιμής ήταν ήσυχια και η οθόνη κενή. Την χρονική στιγμή  $t=2\text{sec}$  ένα ακουστικό ερέθισμα σηματοδοτεί την αρχή της δοκιμής και ειδοποιεί το άτομο για την έναρξη του πειράματος. Το επόμενο 1sec (από  $t=2\text{sec}$  ως  $t=3\text{sec}$ ) εμφανίζεται στην οθόνη ένας σταυρός για να επιστήσει την προσοχή και να προετοιμάσει το άτομο για την εντολή που ακολουθεί. Έπειτα τα επόμενα 6 sec ( $t=3\text{sec}$  ως  $t=9\text{sec}$ ) εμφανίζεται ένα βελάκι με κατεύθυνση δεξιά ή αριστερά και ο χρήστης πρέπει να φανταστεί την αντίστοιχη κίνηση της μπάρας.



Εικόνα 5 : θέσεις ηλεκτροδίων (αριστερά), σχηματική αναπαράσταση της δοκιμής [46].

Το dataset καταγράφηκε από τα κανάλια C3, C4 και Cz (γείωση), σύμφωνα με το διεθνές σύστημα τοποθέτησης ηλεκτροδίων 10-20. Η συσκευή καταγραφής ήταν ένας ενισχυτής G.tec [47] στον οποίο συνδέονταν 3 ηλεκτρόδια χλωριούχου αργύρου [48].

Η συχνότητα δειγματοληψίας είναι 128Hz και το σήμα φιλτράρεται στο διάστημα 0.5-30 Hz.

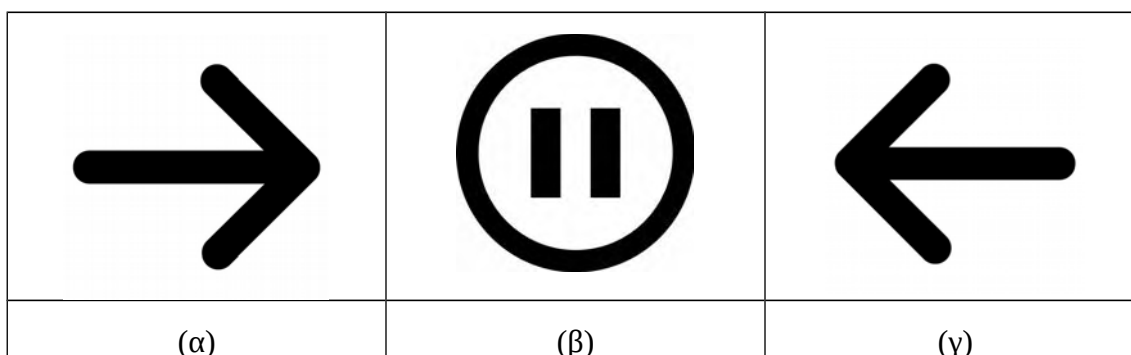
Συνολικά διατίθενται 280 δοκιμές, οι οποίες χωρίζονται στα `x_train`, `x_test` datasets που αποτελούνται από 140 δοκιμές. Επίσης δίνεται ο πίνακας `y_train` με τις κλάσεις των `train data` που περιέχουν τις τιμές '1' (κίνηση αριστερού χεριού), '2' (κίνηση δεξιού χεριού).

Στην παρούσα εργασία έγινε χρήση των `x_train`, `y_train` για feature extraction και ταξινόμηση.

### 3.2 *Emotiv Epor dataset*

Τα 4 συνολικά dataset λήφθηκαν από ένα άτομο (το φοιτητή που πραγματοποίησε την εργασία), δύο ανά ημέρα σε δυο διαφορετικές μέρες. Κατά τη διάρκεια των πειραμάτων το άτομο καθόταν σε καρέκλα και ακουμπούσε τα χέρια του σε τραπέζι, ενώ κοιτούσε την οθόνη υπολογιστή. Σκοπός των πειραμάτων ήταν να πραγματοποιηθεί `motor imagery` αριστερού/δεξιού χεριού ανάλογα με το βέλος (εικόνα) που εμφανιζόταν στην οθόνη. Η διαφορά στη μέθοδο καταγραφής των δύο ημερησίων dataset είναι ότι στο πρώτο ο χρήστης κινούσε ένα joystick με το δεξί ή αριστερό του χέρι ανάλογα με την εντολή `motor imagery` που έπρεπε να εκτελέσει, ενώ στο δεύτερο dataset σκεφτόταν μόνο την κίνηση. Κάθε πείραμα αποτελείται από 12 επαναλήψεις στις οποίες ο χρήστης εκτελεί με τυχαία σειρά ισάριθμα `motor imagery` δεξιού/αριστερού χεριού. Στη διάρκεια του πειράματος το άτομο κοιτούσε την οθόνη και περίμενε ένα ακουστικό ερέθισμα που του επιστούσε την προσοχή για την εικόνα που ακολουθούσε και την κίνηση που έπρεπε να σκεφτεί. Μελετούνται 2 ειδών κινήσεις: προς τα δεξιά και προς τα αριστερά. Με την εμφάνιση είτε της εικόνας που φαίνεται στο Σχήμα (1)(α), είτε αυτής στο Σχήμα (1)(γ) άρχιζε η καταγραφή του EEG για 10 sec. Έπειτα η καταγραφή σταματούσε και εμφανιζόταν η εικόνα διαλλείματος (`pause`) για 10sec -βλ Σχήμα (1)(β). Συνολικά για κάθε dataset έγιναν 10 δοκιμές με ενδιάμεσα διαλλείματα λίγων λεπτών, δίνοντας σύνολο 120 επαναλήψεων για κάθε dataset, ενώ παράλληλα αποθηκεύτηκαν οι 120 αντίστοιχες ετικέτες με την τιμή '1' (κίνηση δεξιού χεριού), '2' (κίνηση αριστερού χεριού).

Τα dataset καταγράφηκαν από τα κανάλια F3,F4 του `emotiv` σύμφωνα με το σύστημα 10-20. Η συχνότητα δειγματοληψίας είναι 128Hz και το σήμα έχει εύρος 0-45Hz.



Σχήμα 1. Εικόνες που βλέπει ο χρήστης κατά τη διάρκεια των πειραμάτων  
[[www.designofsignage.com](http://www.designofsignage.com)]

## 4 Αποτελέσματα

### 4.1 Διανύσματα χαρακτηριστικών BCI Competition

Για τα δεδομένα του BCI Competition II, δύο είδη διανυσμάτων χαρακτηριστικών δημιουργήθηκαν με το dataset `x_train`. Οι μέθοδοι feature extraction εφαρμόζονται στα κανάλια C3, C4 των πειραμάτων στο διάστημα  $t=[3,9]$ , αφού από εκεί ουσιαστικά ξεκινά η διαδικασία του MI στα πειράματα. Για το πρώτο διάνυσμα χαρακτηριστικών (feature vector 1) εφαρμόζεται στα κανάλια C3, C4 DWT ξεχωριστά στο κάθε ένα. Αυτό γίνεται και για τα 140 πειράματα του train dataset με κάθε διαφορετικό mother wavelet (daubechies2, daubechies4, coiflet2, coiflet4, symlet2, symlet4) και δημιουργούνται 6 διαφορετικοί πίνακες χαρακτηριστικών (feature tables) ένας για κάθε mother wavelet. Τα χαρακτηριστικά που δημιουργούν το feature vector εξάγονται από τον DWT χρησιμοποιώντας τα σύνολα συντελεστών:

- Detail2 (16-32Hz) που αντιστοιχούν κατά κύριο λόγο στο ρυθμό beta,
- Detail3 (8-16Hz) που αντιστοιχούν κατά κύριο λόγο στο ρυθμό mu.

Για κάθε σύνολο συντελεστών εξάγονται 8 χαρακτηριστικά δίνοντας ένα διάνυσμα συνολικά 16 στοιχείων, όπως φαίνεται στον Πίνακα (8).

**Πίνακας 8.** Περιγραφή του διανύσματος χαρακτηριστικών 1 (Feature Vector 1) με την εφαρμογή DWT σε ένα πείραμα από το dataset `x_train`

A/A Χαρακτηριστικού	Ηλεκτρόδιο	Ορισμός χαρακτηριστικού
1	C3	max(D2)
2	C3	min(D2)
3	C3	mean(D2)
4	C3	std(D2)
5	C3	max(D3)
6	C3	min(D3)
7	C3	mean(D3)
8	C3	std(D3)
9	C4	max(D2)
10	C4	min(D2)
11	C4	mean(D2)
12	C4	std(D2)
13	C4	max(D3)
14	C4	min(D3)
15	C4	mean(D3)
16	C4	std(D3)

Για το δεύτερο διάνυσμα χαρακτηριστικών (feature vector 2) εφαρμόζεται ξεχωριστά στο κανάλι C3 και στο κανάλι C4 τόσο ο DWT και τα ζωνοπερατά φίλτρα Chebychev με ζώνες διέλευσης [8-12Hz] ( $\mu$ ), [18-26Hz] ( $\beta$ ). Αυτό γίνεται και για 140 πειράματα του train dataset για κάθε μία από τις 6 mother wavelet συναρτήσεις και δημιουργούνται 6 διαφορετικά feature vector. Στη μέθοδο αυτή τα features εξάγονται ανα 2sec στα διαστήματα [3-5sec], [5-7sec], [7-9sec] χωρίζοντας τα C3, C4 στα αντίστοιχα υποσήματα. Τα χαρακτηριστικά που προκύπτουν για κάθε υποσήμα με τον DWT και με τα φίλτρα chebychev, περιγράφονται στον Πίνακα (9). Για παράδειγμα αν εφαρμοστεί DWT με mother wavelet το db2 και τα φίλτρα chebychev στα train data προκύπτει ένα feature table 140x36.

**Πίνακας 9.** Περιγραφή του διανύσματος χαρακτηριστικών 2 (**Feature Vector 2**) από την εφαρμογή του DWT και φίλτρων Chebychev σε ένα πείραμα από το dataset  $x_{train}$ , στα υποδιαστήματα των 2sec

A/A Χαρακτηριστικού	Ηλεκτρόδιο	Ορισμός χαρακτηριστικού	Χρονικό διάστημα
1	C3	mean(abs(D2))	3-5 sec
2	C3	std(D2)	3-5 sec
3	C3	max(abs(beta))	3-5 sec
4	C3	max(abs(mu))	3-5 sec
5	C3	mean(abs(D3))	3-5 sec
6	C3	std(D3)	3-5 sec
7	C3	mean(abs(D2))	5-7 sec
8	C3	std(D2)	5-7 sec
9	C3	max(abs(beta))	5-7 sec
10	C3	max(abs(mu))	5-7 sec
11	C3	mean(abs(D3))	5-7 sec
12	C3	std(D3)	5-7 sec
13	C3	mean(abs(D2))	7-9 sec
14	C3	std(D2)	7-9 sec
15	C3	max(abs(beta))	7-9 sec
16	C3	max(abs(mu))	7-9 sec
17	C3	mean(abs(D3))	7-9 sec
18	C3	std(D3)	7-9 sec
19	C4	mean(abs(D2))	3-5 sec
20	C4	std(D2)	3-5 sec

21	C4	max(abs(beta))	3-5 sec
22	C4	max(abs(mu))	3-5 sec
23	C4	mean(abs(D3))	3-5 sec
24	C4	std(D3)	3-5 sec
25	C4	mean(abs(D2))	5-7 sec
26	C4	std(D2)	5-7 sec
27	C4	max(abs(beta))	5-7 sec
28	C4	max(abs(mu))	5-7 sec
29	C4	mean(abs(D3))	5-7 sec
30	C4	std(D3)	5-7 sec
31	C4	mean(abs(D2))	7-9 sec
32	C4	std(D2)	7-9 sec
33	C4	max(abs(beta))	7-9 sec
34	C4	max(abs(mu))	7-9 sec
35	C4	mean(abs(D3))	7-9 sec
36	C4	std(D3)	7-9 sec

Στη συνέχεια δίνονται οι πίνακες με τη μέση και μέγιστη ακρίβεια ταξινόμησης για τους ακόλουθους ταξινομητές: LDA, SVM, k-NN, μετά από 100 επαναλήψεις της ταξινόμησης για τον καθένα.

## 4.2 Ακρίβεια ταξινόμησης των data του BCI Competition

Κάθε διαφορετικό feature table που προκύπτει με τις μεθόδους εξαγωγής χαρακτηριστικών χωρίζεται από το matlab σε δυο μέρη με τυχαίο τρόπο. Το 50% των δεδομένων επιλέγονται τυχαία και χρησιμοποιούνται για εκπαίδευση (train data) και το υπόλοιπο για δοκιμή του αλγόριθμου ταξινόμησης (test data).

### 4.2.1 Linear Discriminant Analysis

Εφαρμογή του αλγόριθμου LDA στους διαφορετικούς πίνακες δεδομένων με διάνυσμα χαρακτηριστικών 1 και 2. Συνολικά έγιναν 100 επαναλήψεις της διαδικασίας train - test του ταξινομητή.

**Πίνακας 10.** Μέση ποσοστιαία ακρίβεια (υπολογισμένη σε 100 επαναλήψεις) της ταξινόμησης, μετρημένη στα δεδομένα ελέγχου που επιτεύχθηκε από τον ταξινομητή **LDA** για διαφορετικές συναρτήσεις διαχωρισμού δεδομένων, χρησιμοποιώντας το **Feature Vector 1** για διαφορετικά είδη μητρικού Wavelet

Συνάρτηση διαχωρισμού LDA	Είδος μητρικού Wavelet					
	Coif2	Coif4	Db2	Db4	Sym2	Sym4
linear	74.62	77.23	74.94	74.67	74.49	75.17
quadratic	67.58	65.37	65.52	63.09	65.23	62.3
diaglinear	68.82	68.33	67.34	68.12	67.92	68.55
diagquadratic	66.10	65.73	67.12	65.74	66.55	66.0
pseudolinear	75.02	76.68	73.13	73.85	74.1	75.65
pseudoquadratic	67.31	66.67	64.3	64.78	65.27	67.78

**Πίνακας 11.** Μέση ποσοστιαία ακρίβεια ταξινόμησης από 100 επαναλήψεις, μετρημένη στα δεδομένα ελέγχου που επιτεύχθηκε από τον ταξινομητή **LDA** για διαφορετικές συναρτήσεις διαχωρισμού δεδομένων, χρησιμοποιώντας το **Feature Vector 2** για διαφορετικά είδη μητρικού Wavelet

Συνάρτηση διαχωρισμού LDA	Είδος μητρικού Wavelet					
	Coif2	Coif4	Db2	Db4	Sym2	Sym4
linear	73.51	71.97	70.78	76.01	70.44	74.53
diaglinear	66.28	65.44	65.99	65.60	67.04	65.46
diagquadratic	60.53	60.09	62.17	60.85	61.42	59.67
pseudolinear	57.94	61.15	59.38	60.67	59.43	62.85
pseudoquadratic	49.96	48.58	49.30	48.83	49.81	49.17

#### 4.2.2 Support Vector Machine

Εφαρμογή του αλγορίθμου SVM στους διαφορετικούς πίνακες δεδομένων με διάνυσμα χαρακτηριστικών 1 και 2. Συνολικά έγιναν 100 επαναλήψεις της διαδικασίας train - test του ταξινομητή.

**Πίνακας 12.** Μέση ποσοστιαία ακρίβεια ταξινόμησης (100 επαναλήψεις) μετρημένη στα δεδομένα ελέγχου που επιτεύχθηκε από τον ταξινομητή SVM για διαφορετικές συναρτήσεις διαχωρισμού δεδομένων, χρησιμοποιώντας το **Feature Vector 1** για διαφορετικά είδη μητρικού Wavelet

	<b>Είδος μητρικού Wavelet</b>					
<b>Συνάρτηση διαχωρισμού SVM</b>	<b>Coif2</b>	<b>Coif4</b>	<b>Db2</b>	<b>Db4</b>	<b>Sym2</b>	<b>Sym4</b>
gaussian	56.62	56.6	56.18	60.89	56.88	56.98
rbf (radial basis function)	57.07	57.03	56.81	60.98	56.77	57.02
linear	76.13	77.64	73.29	75.88	73.67	74.21
polynomial	68.66	68.54	69.62	68.17	70.49	66.90

**Πίνακας 13.** Μέση ποσοστιαία ακρίβεια ταξινόμησης (100 επαναλήψεις) μετρημένη στα δεδομένα ελέγχου που επιτεύχθηκε από τον ταξινομητή SVM για διαφορετικές συναρτήσεις διαχωρισμού δεδομένων, χρησιμοποιώντας το **Feature Vector 2** για διαφορετικά είδη μητρικού Wavelet.

	<b>Είδος μητρικού Wavelet</b>					
<b>Συνάρτηση διαχωρισμού SVM</b>	<b>Coif2</b>	<b>Coif4</b>	<b>Db2</b>	<b>Db4</b>	<b>Sym2</b>	<b>Sym4</b>
gaussian	50.23	49.45	51.36	48.63	50.98	50.83
rbf	49.65	49.39	50.99	48.31	50.55	50.83
linear	78.67	79.48	76.62	78.86	75.88	79.56
polynomial	70.76	70.13	69.57	71.05	70.51	73.52

### 4.2.3 k Nearest Neighbors

Όπως περιγράφηκε στην παρ. 2.2.3, αρχικά επιλέχθηκε η βέλτιστη τιμή της παραμέτρου  $k$  (αριθμός γειτόνων) σε ακτίνα τιμών [1,20], ως η τιμή που επιτυγχάνει το μικρότερο σφάλμα ταξινόμησης με 10 fold cross-validation για κάθε μετρική της απόστασης, για το Feature Vector 1 (Πίνακας 14) και 2 (Πίνακας 16). Στη συνέχεια έγινε εφαρμογή του αλγορίθμου k-NN στα διανύσματα χαρακτηριστικών 1 και 2 (Feature Vector 1, 2), για όλα τα είδη του μητρικού wavelet, χρησιμοποιώντας τις



βέλτιστες τιμές της παραμέτρου  $k$ , (Πίνακες 14, 16). Συνολικά έγιναν 100 επαναλήψεις της διαδικασίας train - test του ταξινομητή. Οι μέσες ακρίβειες παρουσιάζονται στους Πίνακες (15) και (17), για τα (Feature Vector 1, 2) αντίστοιχα.

**Πίνακας 14.** Ο βέλτιστος αριθμός γειτόνων  $k$  για κάθε μετρική της απόστασης χρησιμοποιώντας το **Feature Vector 1**

	<b>Είδος μητρικού Wavelet</b>					
<b>Συνάρτηση διαχωρισμού kNN</b>	Coif2	Coif4	Db2	Db4	Sym2	Sym4
cityblock	8	7	9	17	9	14
chebychev	14	11	6	14	6	16
correlation	16	8	15	14	15	15
cosine	16	10	18	13	18	16
euclidean	6	14	10	14	10	18
hamming	20	20	20	20	20	20
jaccard	20	20	20	20	20	20
mahalanobis	19	18	16	15	16	20
minkowski	8	10	11	13	11	20
seuclidean	7	15	11	19	11	19
spearman	8	7	9	19	9	20

**Πίνακας 15.** Μέση ποσοστιαία ακρίβεια ταξινόμησης (100 επαναλήψεις) μετρημένη στα δεδομένα ελέγχου που επιτεύχθηκε από τον ταξινομητή **k-NN** για διαφορετικές συναρτήσεις διαχωρισμού δεδομένων, χρησιμοποιώντας το **Feature Vector 1** για διαφορετικά είδη μητρικού Wavelet. Χρησιμοποιήθηκαν οι βέλτιστες τιμές του **k** που υπολογίστηκαν στον Πίνακα (14).

	<b>Είδος μητρικού Wavelet</b>					
<b>Συνάρτηση διαχωρισμού kNN</b>	Coif2	Coif4	Db2	Db4	Sym2	Sym4
cityblock	71,72	70,58	72,14	70,52	72,54	71,71
chebychev	65,60	68,59	64,45	65,061	64,73	62,42
correlation	68,27	68,56	69,13	68,96	69,56	68,63
cosine	68,39	67,60	67,96	68,97	67,42	68,02
euclidean	70,72	68,44	71,31	70,27	71,14	69,15
hamming	50	50	50	50	50	50
jaccard	50	50	50	50	50	50
mahalanobis	69,35	69,68	70,48	68,05	70,91	70,39
minkowski	70,43	70,15	71,29	70,31	71,32	68,73
seuclidean	71,34	68,72	70,42	69,35	70,55	69,57
spearman	51,58	69,85	72,98	70,41	72,5	70,64

**Πίνακας 16 .** Ο βέλτιστος αριθμός γειτόνων **k** για κάθε μετρική της απόστασης χρησιμοποιώντας το **Feature Vector 2**

	<b>Είδος μητρικού Wavelet</b>					
<b>Συνάρτηση διαχωρισμού kNN</b>	Coif2	Coif4	Db2	Db4	Sym2	Sym4
cityblock	18	18	14	10	14	20
chebychev	20	20	13	13	13	15
correlation	20	20	16	20	16	20
cosine	17	17	11	17	11	17
euclidean	15	12	18	13	18	19

hamming	20	20	20	20	20	20
jaccard	20	20	20	20	20	20
minkowski	19	20	20	15	20	19
seuclidean	15	13	19	19	19	20
spearman	14	10	17	14	17	17

**Πίνακας 17.** Μέση ποσοστιαία ακρίβεια (υπολογισμένη σε 100) επαναλήψεις ταξινόμησης, μετρημένη στα δεδομένα ελέγχου που επιτεύχθηκε από τον ταξινομητή **k-NN** για διαφορετικές συναρτήσεις διαχωρισμού δεδομένων, χρησιμοποιώντας το **Feature Vector 2** για διαφορετικά είδη μητρικού Wavelet. Χρησιμοποιήθηκαν οι βέλτιστες τιμές του **k** που υπολογίστηκαν στον Πίνακα 16

	<b>Είδος μητρικού Wavelet</b>					
<b>Συνάρτηση διαχωρισμού kNN</b>	Coif2	Coif4	Db2	Db4	Sym2	Sym4
cityblock	75,38	75,18	76,45	74,91	76,35	75,61
chebychev	77,30	76,79	75,78	77,76	75,86	77,33
correlation	79,90	78,96	78,72	79,95	77,65	80,33
cosine	75,83	75,07	76,70	76,12	76,50	76,30
euclidean	77,23	77,54	77,16	77,50	77,48	75,91
hamming	50	50	50	50	50	50
jaccard	50	50	50	50	50	50
minkowski	75,72	74,93	76,61	77,19	76,13	76,17
seuclidean	76,71	77,15	76,41	76,31	76,62	75,74
spearman	77,62	76,65	78,90	78,17	79,19	79,58

#### **4.2.4 Νευρωνικά Δίκτυα - Multilayer Perceptron**

Από τις 140 γραμμές των feature table το 70% (98 γραμμές του feature table) χρησιμοποιούνται για training του δικτύου, 15 % (21 γραμμές του feature table) για έλεγχο κατά τη διάρκεια της εκπαίδευσης (validation) και 15% για testing. Ο διαχωρισμός σε υποσύνολο εκπαίδευσης (training), επαλήθευσης (validation) και

ελέγχου (test set) λαμβάνει χώρα τυχαία σε κάθε εκτέλεση. Η εκπαίδευση του δικτύου χωρίζεται σε επαναλήψεις της ανατροφοδότησης με όλα τα training data (εποχές-epochs), αναπροσαρμόζοντας τα βάρη των συνδέσεων μεταξύ των νευρώνων. Τα δεδομένα επαλήθευσης χρησιμοποιούνται για να μετρήσουν τη γενίκευση (generalization) του δικτύου και σταματούν την εκπαίδευση όταν η γενίκευση παύει να βελτιώνεται. Τα test data αποτελούν το τελικό μέτρο της απόδοσης του δικτύου μετά το τέλος της εκπαίδευσης. Συνολικά για τις δυο μεθόδους εξαγωγής χαρακτηριστικών γίνονται 10 πειράματα [50]. Η ακρίβεια ταξινόμησης μετράται στο σύνολο των δεδομένων, δηλαδή στα training, validation, test data. Οι μέσες ακρίβειες που επιτεύχθηκαν χρησιμοποιώντας 10 και 15 νευρώνες στο κρυφό επίπεδο, για το feature Vector 1 και 2, δίνονται στους Πίνακες (18), (19), (20) και (21).

**Πίνακας 18.** Μέση ποσοστιαία ακρίβεια ταξινόμησης (10 επαναλήψεις), μετρημένη στα δεδομένα εκπαίδευσης, ελέγχου και επαλήθευσης που επιτεύχθηκε από το νευρωνικό δίκτυο για διαφορετικές συναρτήσεις διαχωρισμού δεδομένων, χρησιμοποιώντας το **Feature Vector 1** για διαφορετικά είδη μητρικού Wavelet με 10 κρυφούς νευρώνες.

Συνάρτηση εκπαίδευσης δικτύου	Είδος μητρικού Wavelet					
	Coif2	Coif4	Db2	Db4	Sym2	sym4
trainscg	81.42	84	79.92	79.92	79.21	81.57
trainbfg	84.78	83.36	83.93	82.24	83.92	84.78
trainrp	83.42	86.21	84.35	82.28	83.42	84.64
traincgb	84.71	84.07	84.57	86.42	85.07	85.57
traincgf	82.93	84.92	84.07	82.35	83.57	86.0
traincgp	84.57	85.85	83.07	84.5	83.92	83.42
traingdx	78.79	84.64	77.64	85.28	82.07	85.07
trainbr	79.28	96.14	77.57	75.28	74.21	95.5

**Πίνακας 19.** Μέση ποσοστιαία ακρίβεια ταξινόμησης (10 επαναλήψεις) μετρημένη στα δεδομένα εκπαίδευσης, ελέγχου και επαλήθευσης που επιτεύχθηκε από το νευρωνικό δίκτυο για διαφορετικές συναρτήσεις διαχωρισμού δεδομένων, χρησιμοποιώντας το **Feature Vector 1** για διαφορετικά είδη μητρικού Wavelet με 15 κρυφούς νευρώνες.

Συνάρτηση εκπαίδευσης δικτύου	Είδος μητρικού Wavelet					
	Coif2	Coif4	Db2	Db4	Sym2	sym4
trainscg	78.71	76.71	78.07	79.85	79.64	78.57
trainbfg	83.35	81.36	84.5	84.42	80.57	81.92
trainrp	84.64	83.14	81.71	84.85	84.35	86.35
traincgb	80.14	81.36	84.07	84.92	83.64	84.57
traincgf	85.42	83.71	85.0	82.5	82.85	84.64
traincgp	84.93	84.14	82.71	82.35	83.57	80.92
traingdx	84.42	78.35	73.64	80.71	81.0	84.35
trainbr	81.78	63.5	78.0	75.28	79.5	50

**Πίνακας 20.** Μέση ποσοστιαία ακρίβεια ταξινόμησης (10 επαναλήψεις) μετρημένη στα δεδομένα εκπαίδευσης, ελέγχου και επαλήθευσης που επιτεύχθηκε από το νευρωνικό δίκτυο για διαφορετικές συναρτήσεις διαχωρισμού δεδομένων, χρησιμοποιώντας το **Feature Vector 2** για διαφορετικά είδη μητρικού Wavelet με 10 κρυφούς νευρώνες.

Συνάρτηση εκπαίδευσης δικτύου	Είδος μητρικού Wavelet					
	Coif2	Coif4	Db2	Db4	Sym2	sym4
trainscg	82.71	80.57	83.78	85.5	84.28	85.14
trainbfg	81.07	83.35	83.5	83.28	82.85	84.5
trainrp	86.71	84.78	82.92	83.78	82.28	84.92
traincgb	83.28	86.21	85.42	82.57	83.85	86.28
traincgf	83.71	84.07	83.5	84.92	83.78	86.21
traincgp	84.07	86.14	81.64	83.78	83.64	83.57
traingdx	80.07	85.21	84.71	83.07	84.64	84.35
trainbr	63.92	66.21	65.21	59.35	64.07	59.42

**Πίνακας 21.** Μέση ποσοστιαία ακρίβεια ταξινόμησης (10 επαναλήψεις) μετρημένη στα δεδομένα εκπαίδευσης, ελέγχου και επαλήθευσης που επιτεύχθηκε από το νευρωνικό δίκτυο για διαφορετικές συναρτήσεις διαχωρισμού δεδομένων, χρησιμοποιώντας το **Feature Vector 2** για διαφορετικά είδη μητρικού Wavelet με 15 κρυφούς νευρώνες.

Συνάρτηση εκπαίδευσης δικτύου	Είδος μητρικού Wavelet					
	Coif2	Coif4	Db2	Db4	Sym2	sym4
trainscg	86.07	86.92	83.92	82.5	85.85	83.57
trainbfg	85.85	85.35	85.14	84.64	84.92	87.07
trainrp	87.07	82.71	83.85	80.5	84.85	83.92
traincgb	85.07	85.92	81.92	84.92	81.57	85.78
traincgf	86.92	85.35	85.0	83.5	84.28	83.5
traincgp	85.14	82.57	83.92	85.64	84.5	84.07
traingdx	83.85	82.07	77.64	84.64	81.5	83.78
trainbr	82.78	78.07	73.07	68.14	59.42	73.78

### 4.3 Διανύσματα χαρακτηριστικών *Emotiv Eroc*

Για τα δεδομένα που λήφθηκαν με τον ηλεκτροεγκεφαλογράφο Emotiv Eroc δημιουργήθηκαν 6 είδη διανυσμάτων χαρακτηριστικών από τα κανάλια F3, F4 των πειραμάτων στο διάστημα  $t=[1-10s]$ , όσο διαρκεί η διαδικασία Motor Imagery σε κάθε πείραμα. Για το πρώτο είδος διανύσματος χαρακτηριστικών (feature vector 1-FV1) εφαρμόζεται στο DWT των καναλιών F3, F4. Αυτό γίνεται και για τα 120 πειράματα κάθε dataset με κάθε διαφορετικό mother wavelet (daubechies2, daubechies4, coiflet2, coiflet4, symlet2, symlet4) και δημιουργούνται 6 διαφορετικοί πίνακες χαρακτηριστικών (feature tables) ένας για κάθε mother wavelet. Τα features που δημιουργούν το feature vector εξάγονται από τα Detail2(16-32 Hz), Detail3(8-16Hz) και είναι: η μέγιστη τιμή  $\max(D2)$ , ελάχιστη τιμή  $\min(D2)$ , μέση τιμή  $\text{mean}(D2)$ , τυπική απόκλιση  $\text{std}(D2)$ ,  $\max(D3)$ ,  $\min(D3)$ ,  $\text{mean}(D3)$ . Για παράδειγμα αν εφαρμοστεί DWT με mother wavelet την daubechies2 σε ένα dataset προκύπτει ένα feature table 120x16.

Για το δεύτερο είδος διανύσματος χαρακτηριστικών (feature vector2 - FV2), χρησιμοποιούνται τα ίδια χαρακτηριστικά με το Feature Vector1 και επιπλέον με τα φίλτρα Chebychev οι μέγιστες τιμές πλάτους στο πεδίο της συχνότητας των ρυθμών  $\beta(18-26\text{Hz})$ ,  $\mu(8-12\text{Hz})$ . Για το τρίτο είδος διανύσματος χαρακτηριστικών (feature vector3-FV3) με την εφαρμογή DWT στα κανάλια F3,F4 εξάγονται ως χαρακτηριστικά από τα Detail2, Detail3 η νόρμα1 ( $\text{norm}(D2,1)$ ), νόρμα2 ( $\text{norm}(D2,2)$ ), νόρμα άπειρο ( $\text{norm}(D2,\text{inf})$ ), εύρος τιμών ( $\text{range}(D2)$ ) (μέγιστη-

ελάχιστη τιμή), η πιο συχνά εμφανιζόμενη τιμή  $\text{mode}(D2)$ ,  $\text{norm}(D3,1)$ ,  $\text{norm}(D3,2)$ ,  $\text{norm}(D3,\text{inf})$ ,  $\text{mode}(D3)$ ,  $\text{range}(D3)$ .

Για το τέταρτο είδος διανύσματος χαρακτηριστικών (feature vector4-FV4) εφαρμόζεται DWT στα κανάλια F3,F4 και εξάγονται τα ίδια features με τον feature vector 3, καθώς και με τα φίλτρα Chebychev οι μέγιστες τιμές πλάτους στο πεδίο της συχνότητας των ρυθμών  $\beta$ ,  $\mu$ ,  $\max(\text{abs}(\beta))$ ,  $\max(\text{abs}(\mu))$ . Για το πέμπτο είδος διανύσματος χαρακτηριστικών (feature vector5-FV5) εφαρμόζεται DWT στα κανάλια F3, F4 και ως features εξάγονται από τα Detail2,Detail3 τα  $\text{mean}(D2)$ ,  $\text{std}(D2)$ ,  $\text{range}(D2)$ ,  $\text{mode}(D2)$ . Για το έκτο είδος διανύσματος χαρακτηριστικών (feature vector 6 FV6) εφαρμόζεται DWT στα κανάλια F3, F4 και ως features εξάγονται τα ίδια με το fv5 και επιπλέον με τα φίλτρα Chebychev οι μέγιστες τιμές πλάτους των συχνοτήτων των ρυθμών  $\beta$ ,  $\mu$ .

Τα έξι είδη διανυσμάτων χαρακτηριστικών περιγράφονται στον Πίνακα (22).

**Πίνακας 22.** Τα 6 είδη διανυσμάτων χαρακτηριστικών που εξάγονται από κάθε dataset με κάθε διαφορετικό wavelet.

	features	Fv1	Fv2	Fv3	Fv4	Fv5	Fv6
<b>D</b> <b>W</b> <b>T</b>	Max	D2,D3	D2,D3	D2,D3	D2,D3	D2,D3	D2,D3
	Min	D2,D3	D2,D3	D2,D3	D2,D3	D2,D3	D2,D3
	Mean	D2,D3	D2,D3	D2,D3	D2,D3	D2,D3	D2,D3
	Std	D2,D3	D2,D3	D2,D3	D2,D3	D2,D3	D2,D3
	Range	D2,D3	D2,D3	D2,D3	D2,D3	D2,D3	D2,D3
	Mode	D2,D3	D2,D3	D2,D3	D2,D3	D2,D3	D2,D3
	Norm1	D2,D3	D2,D3	D2,D3	D2,D3	D2,D3	D2,D3
	Norm2	D2,D3	D2,D3	D2,D3	D2,D3	D2,D3	D2,D3
	Norm $\infty$	D2,D3	D2,D3	D2,D3	D2,D3	D2,D3	D2,D3
<b>C</b>	Beta	Max(abs)	Max(abs)	Max(abs)	Max(abs)	Max(abs)	Max(abs)
<b>H</b>	Mu	Max(abs)	Max(abs)	Max(abs)	Max(abs)	Max(abs)	Max(abs)

#### 4.4 Ακρίβεια ταξινόμησης των dataset του Emotiv Eroc

Κάθε διαφορετικό feature table που προκύπτει με τις 6 μεθόδους εξαγωγής χαρακτηριστικών χωρίζεται από το matlab σε δυο μέρη με τυχαίο τρόπο. Το 50% των δεδομένων επιλέγονται τυχαία και χρησιμοποιούνται για εκπαίδευση (train data) και το υπόλοιπο για δοκιμή του αλγορίθμου ταξινόμησης (test data). Τα 6 feature vectors δόθηκαν με την παραπάνω μέθοδο διαχωρισμού στους ταξινομητές LDA,SVM,k-NN, για κάθε ένα από τα 4 πειράματα EEG που καταγράφηκαν. Το εύρος τιμών για τις μέσες ακρίβειες είναι παρόμοιο για αυτό το λόγο παρατίθενται μόνο τα αποτελέσματα των LDA,SVM για τις μεθόδους εξαγωγής χαρακτηριστικών 1 και 3 του EEG dataset που λήφθηκε την πρώτη μέρα με τη βοήθεια του joystick.

#### 4.4.1 Linear Discriminant Analysis

**Πίνακας 23.** Μέση ποσοστιαία ακρίβεια (υπολογισμένη σε 100 επαναλήψεις) της ταξινόμησης μετρημένη στα δεδομένα ελέγχου που επιτεύχθηκε από τον ταξινομητή **LDA** για διαφορετικές συναρτήσεις διαχωρισμού δεδομένων, χρησιμοποιώντας το **Feature Vector 1** για διαφορετικά είδη μητρικού Wavelet

Συνάρτηση διαχωρισμού LDA	Είδος μητρικού Wavelet					
	Coif2	Coif4	Db2	Db4	Sym2	Sym4
linear	56.67	65	68.33	60	60	55
quadratic	58.33	61.67	60	48.33	63.33	53.33
diaglinear	53.33	41.67	56.67	48.33	61.67	51.67
diagquadratic	51.67	46.67	55	46.67	56.67	45
pseudolinear	63.33	63.33	55	60	55	48
pseudoquadratic	53.33	55	60	53.33	60	53.33

**Πίνακας 24.** Μέση ποσοστιαία ακρίβεια (υπολογισμένη σε 100 επαναλήψεις) της ταξινόμησης μετρημένη στα δεδομένα ελέγχου που επιτεύχθηκε από τον ταξινομητή **LDA** για διαφορετικές συναρτήσεις διαχωρισμού δεδομένων, χρησιμοποιώντας το **Feature Vector 3** για διαφορετικά είδη μητρικού Wavelet

Συνάρτηση διαχωρισμού LDA	Είδος μητρικού Wavelet					
	Coif2	Coif4	Db2	Db4	Sym2	Sym4
linear	56.67	56.67	68.33	50	56.67	55
quadratic	46.67	51.67	60	50	53.33	46.67
diaglinear	50.0	48.33	61.67	50	51.67	61.67
diagquadratic	51.67	58.33	56.67	53.33	55	53.33
pseudolinear	51.67	51.67	63.33	56.67	68.33	53.33
pseudoquadratic	51.67	35	55	48.33	60	51.67



#### 4.4.2 Support vector machine, SVM

**Πίνακας 25.** Μέση ποσοστιαία ακρίβεια (υπολογισμένη σε 100 επαναλήψεις) της ταξινόμησης μετρημένη στα δεδομένα ελέγχου που επιτεύχθηκε από τον ταξινομητή **SVM** για διαφορετικές συναρτήσεις διαχωρισμού δεδομένων, χρησιμοποιώντας το **Feature Vector 1** για διαφορετικά είδη μητρικού Wavelet

	<b>Είδος μητρικού Wavelet</b>					
<b>Συνάρτηση διαχωρισμού SVM</b>	Coif2	Coif4	Db2	Db4	Sym2	Sym4
gaussian	56.67	53.33	53.33	60	55	55
rbf (radial basis function)	46.67	63.33	60	51.67	58.33	46.67
linear	50	56.67	60	55	55	41.67
polynomial	61.67	60	53.33	58.33	61.67	50

**Πίνακας 26.** Μέση ποσοστιαία ακρίβεια (υπολογισμένη σε 100 επαναλήψεις) της ταξινόμησης μετρημένη στα δεδομένα ελέγχου που επιτεύχθηκε από τον ταξινομητή **SVM** για διαφορετικές συναρτήσεις διαχωρισμού δεδομένων, χρησιμοποιώντας το **Feature Vector 3** για διαφορετικά είδη μητρικού Wavelet

	<b>Είδος μητρικού Wavelet</b>					
<b>Συνάρτηση διαχωρισμού SVM</b>	Coif2	Coif4	Db2	Db4	Sym2	Sym4
gaussian	43.33	55	51.67	53.33	55	51.67
rbf (radial basis function)	53.33	66.67	55	51.67	51.67	46.67
linear	60	65	63.33	63.33	65	63.33
polynomial	53.33	55	51.67	43.33	45	55

### 4.4.3 Νευρωνικά Δίκτυα - Multilayer Perceptron

Από τις 120 γραμμές των feature table το 70% (84 γραμμές του feature table) χρησιμοποιούνται για training του δικτύου, 15 % (18 γραμμές του feature table) για έλεγχο κατά τη διάρκεια της εκπαίδευσης (validation) και 15% για testing. Ο διαχωρισμός σε υποσύνολο εκπαίδευσης (training), επαλήθευσης (validation) και ελέγχου (test set) λαμβάνει χώρα τυχαία σε κάθε εκτέλεση. Η εκπαίδευση του δικτύου χωρίζεται σε επαναλήψεις της ανατροφοδότησης με όλα τα training data (εποχές - epochs), αναπροσαρμόζοντας τα βάρη των συνδέσεων μεταξύ των νευρώνων. Τα δεδομένα επαλήθευσης χρησιμοποιούνται για να μετρήσουν τη γενίκευση (generalization) του δικτύου και σταματούν την εκπαίδευση όταν η γενίκευση παύει να βελτιώνεται. Τα test data αποτελούν το τελικό μέτρο της απόδοσης του δικτύου μετά το τέλος της εκπαίδευσης. Συνολικά για τις 6 μεθόδους εξαγωγής χαρακτηριστικών γίνονται 10 πειράματα [50]. Η ακρίβεια ταξινόμησης μετράται στο σύνολο των δεδομένων, δηλαδή στα training, validation και test data. Το εύρος τιμών για τις μέσες ακρίβειες είναι παρόμοιο για αυτό το λόγο παρατίθενται μόνο για την πρώτη μέθοδο εξαγωγής χαρακτηριστικών του EEG dataset που λήφθηκε την πρώτη μέρα με τη βοήθεια του joystick. Στον Πίνακα (27) φαίνονται οι μέσες ακρίβειες ταξινόμησης για το πρώτο είδος διανύσματος χαρακτηριστικών.

**Πίνακας 27.** Μέση ποσοστιαία ακρίβεια ταξινόμησης (10 επαναλήψεις) μετρημένη στα δεδομένα εκπαίδευσης, ελέγχου και επαλήθευσης που επιτεύχθηκε από το νευρωνικό δίκτυο για διαφορετικές συναρτήσεις διαχωρισμού δεδομένων, χρησιμοποιώντας το **Feature Vector 1** για διαφορετικά είδη μητρικού Wavelet με 10 κρυφούς νευρώνες.

Συνάρτηση εκπαίδευσης δικτύου	Είδος μητρικού Wavelet					
	Coif2	Coif4	Db2	Db4	Sym2	sym4
trainbfg	58.0	60.66	63.33	63.75	59.42	61.08
trainbr	62.83	62.58	76.42	50.75	79.75	54.25
traincgb	62.83	59.16	60.33	59.5	60.33	61.66
traincgf	60.75	57.83	63.25	56.25	61.17	62.5
traincgp	65.5	60.92	62.33	56.25	58.25	59.25
traingdx	54.33	56.91	56.83	56.0	53.58	50.75
trainrp	59.92	58.5	55.75	56.25	57.66	56.5
trainscg	59.42	65.5	59.0	59.58	57.75	60.0

#### **4.5 Συμπεράσματα για την ακρίβεια ταξινόμησης των δεδομένων του *Emotiv Eroc***

Όπως φαίνεται, η ταξινόμηση για τα διάφορα feature vectors που δημιουργήθηκαν από το EEG των καναλιών F3, F4 δίνει πολύ φτωχά αποτελέσματα ακρίβειας. Ένας λόγος για αυτό μπορεί να είναι η χρήση αλατούχου διαλύματος στα ηλεκτρόδια που τα οξειδώνει και πιθανώς επηρεάζει την ποιότητα του σήματος.

Ακόμα το *Emotiv* δεν διαθέτει τα ηλεκτρόδια C3, C4 που βρίσκονται άμεσα πάνω από τον εγκεφαλικό φλοιό που σχετίζεται με MI, αλλά τα F3, F4 (λίγο πιο μπροστά από τα C3, C4). Τέλος, η σχεδίαση και εκτέλεση του πειράματος που έγινε με στοιχειώδη τρόπο, χωρίς περαιτέρω υποστήριξη, πιθανόν να συνέβαλε στη μειωμένη ακρίβεια ταξινόμησης.

Στον Πίνακα (23) για τον αλγόριθμο LDA οι συναρτήσεις διαχωρισμού linear, quadratic έδωσαν για τα διάφορα διανύσματα χαρακτηριστικών μέση ακρίβεια στο διάστημα 55-68%, 48-61%. Στον Πίνακα (24), για τον αλγόριθμο LDA οι συναρτήσεις διαχωρισμού linear, quadratic έδωσαν για τα διαφορετικά διανύσματα χαρακτηριστικών μέση ακρίβεια στο διάστημα 50-56%, 46-53%. Στον Πίνακα 25 για τον αλγόριθμο SVM οι συναρτήσεις διαχωρισμού gaussian, linear έδωσαν για τα διαφορετικά διανύσματα χαρακτηριστικών μέση ακρίβεια 43-51%, 63-65%.

Οι ακρίβειες που επιτεύχθηκαν για τα δεδομένα του BCI Competition είναι παρόμοιες με αυτές της βιβλιογραφίας. Στον Πίνακα (10) ο αλγόριθμος LDA με τις συναρτήσεις διαχωρισμού linear, pseudolinear έδωσε για τα διαφορετικά feature vectors μέση ακρίβεια ταξινόμησης στο διάστημα 75-77%. Στον Πίνακα (11) οι συναρτήσεις διαχωρισμού linear, diaglinear έδωσαν για τα διαφορετικά διανύσματα χαρακτηριστικών μέση ακρίβεια ταξινόμησης 70-76%, 65-66%. Στον Πίνακα (15) ο αλγόριθμος k-NN με τις συναρτήσεις διαχωρισμού cityblock, euclidean πέτυχε για τα διαφορετικά διανύσματα χαρακτηριστικών μέση ακρίβεια ταξινόμησης 70-72%, 68-71% αντίστοιχα. Στον Πίνακα (17) ο αλγόριθμος k-NN με τις συναρτήσεις διαχωρισμού cityblock, chebychev πέτυχε για τα διαφορετικά διανύσματα χαρακτηριστικών μέση ακρίβεια στα διαστήματα 74-76%, 75-77%. Στον Πίνακα(18) το νευρωνικό δίκτυο 10 κρυφών νευρώνων πέτυχε για τα διαφορετικά διανύσματα χαρακτηριστικών μέση ακρίβεια στο διάστημα 77-86%. Η βιβλιογραφία [6], [25], [26], [51] για MI δεξιού/αριστερού χεριού επιτυγχάνει παρόμοια ποσοστά ακρίβειας ταξινόμησης. Πιο συγκεκριμένα, αναφέρθηκε ακρίβεια μικρότερη του 70 % με χρήση DWT και ταξινομητή SVM) [6],

- 97% μέγιστη ακρίβεια (ταξινομητής Multilayer Perceptron)
- Στα διαστήματα [68-79%], [73-80%], [75-84%] (ταξινομητής LDA)
- Στο διάστημα [87-90 %] (ταξινομητής LDA)



## 5 Βιβλιογραφία

- [1] L. Hass, "Hans Berger (1873–1941), Richard Caton (1842–1926), and electroencephalography, *J Neurol Neurosurg Psychiatry*. 2003 Jan; 74(1): 9.doi: 10.1136/jnnp.74.1.9
- [2] G.R. Müller-Putz, R. Scherer, G. Pfurtscheller, R. Rupp, "EEG-based neuroprosthesis control: A step towards clinical practice ", *Neuroscience Letters* Volume 382, Issues 1–2, 1–8 July 2005, Pages 169–174
- [3] <http://mentalhealthdaily.com/2014/04/15/5-types-of-brain-waves-frequencies-gamma-beta-alpha-theta-delta/>
- [4] J.R. Wolpaw, N. Birbaumer , D.J. McFarland , et al. "Brain-computer interface for communication and control, " *Clinical Neurophysiology*, vol. 113, 2002, pp. 767-791
- [5] C. Neuper, M. Wörtz, G. Pfurtscheller, "ERD/ERS patterns reflecting sensorimotor activation and deactivation", *Progress in Brain Research* Volume 159, 2006, Pages 211–222
- [6] I. Dokare, N. Kant, "Classification of EEG Signal for Imagined Left and Right Hand Movement for Brain Computer Interface Applications ", *International Journal of Application or Innovation in Engineering & Management (IJAIEM)*
- [7] [https://en.wikipedia.org/wiki/Motor\\_imagery](https://en.wikipedia.org/wiki/Motor_imagery)
- [8] M.R. Nuwer, G. Comi, R. Emerson, A. Fuglsang-Frederiksen, J.M. Guérit, H. Hinrichs , A. Ikeda, F.J. Luccas, P. Rappelsburger, "IFCN standards for digital recording of clinical EEG. *International Federation of Clinical Neurophysiology*", PMID:9743285
- [9] "American Electroencephalographic Society Guidelines for Standard Electrode Position Nomenclature", *J Clin Neurophysiol*. 1991, PMID: 8458991
- [10] G.H. Klem, H. O Lüders, H.H. Jasper, C. Elger, "The ten–twenty electrode system of the International Federation. The International Federation of Clinical Neurophysiology. Cleveland Clinic Foundation", *Electroencephalography and clinical neurophysiology*. Supplement 52:3-6·February 1999
- [11] JR Wolpaw, "Brain–computer interfaces as new brain output pathways", *J Physiol*. 2007 Mar 15;579(Pt 3):613-9. Epub 2007 Jan 25
- [12] [https://en.wikipedia.org/wiki/Brain-computer\\_interface](https://en.wikipedia.org/wiki/Brain-computer_interface)
- [13] C. Guan, M. Thulasidas, J. Wu, "High performance P300 speller for brain-computer interface", *Biomedical Circuits and Systems*, 2004 IEEE International Workshop on Date 1-3 Dec. 2004
- [14] <http://neurosky.com/biosensors/eeg-sensor/biosensors/>
- [15] <http://neurosky.com/biosensors/eeg-sensor/>
- [16] <http://shop.openbci.com/collections/frontpage/products/openbci-32-bit-board-kit?variant=784651699>

- [17] <http://emotiv.com/product/emotiv-epoc-14-channel-mobile-ee/>
- [18] <http://emotiv.com/software/>
- [19] <http://www.donutsites.com/emotiv-ftp/Emotiv-EPOC-Product-Sheet-2014.pdf>
- [20] E. Derya Übeyli , "Statistics over features: EEG signals analysis", *Computers in Biology and Medicine*, August 2009 Volume 39, Issue 8, Pages 733-741
- [21] S. Soltani , "On the use of the wavelet decomposition for time series prediction", *Neurocomputing* 48 (2002) 267–277
- [22] I. Daubechies, "The wavelet transform, time-frequency localization and signal analysis", *IEEE Transactions on Information Theory* (Volume:36 , Issue: 5)
- [23] A.S. Al-Fahoum, A. A. Al-Fraihat, "Methods of EEG Signal Features Extraction Using Linear Analysis in Frequency and Time-Frequency Domains", *ISRN Neuroscience* Volume 2014 (2014), Article ID 730218, 7 pages
- [24] <http://polyvalens.pagesperso-orange.fr/clemens/wavelets/wavelets.html#eq2>
- [25] P. Jahanhahi, V.S. Kodogiannis, K.R. Revett, "EEG signal classification using wavelet feature extraction and neural networks", *JVA '06 Proceedings of the IEEE John Vincent Atanasoff 2006 International Symposium on Modern Computing* Pages 120-124
- [26] Y. Fang, X. Zheng , "Feature Extraction of Time-Amplitude-Frequency Analysis for Classifying Single EEG", *Journal of Fiber Bioengineering and Informatics* 2014, Vol. 7
- [27] F. Lotte, M. Congedo, A. L'ecuyer , F. Lamarche, B. Arnaldi, "A review of classification algorithms for EEG-based brain-computer interfaces", *Journal of Neural Engineering*, IOP Publishing, 2007, 4, pp.24
- [28] R. Aldea, M. Fira, "Classifications of Motor Imagery Tasks in Brain Computer Interface Using Linear Discriminant Analysis", *Artificial Intelligence (IJARAI)*, Volume 3 Issue 7, 2014.
- [29] Y. Wang, B. Hong, X. Gao, and S. Gao, "Implementation of a Brain-Computer Interface Based on Three States of Motor Imagery", *Proceedings of the 29th Annual International Conference of the IEEE EMBS Cité Internationale, Lyon, France August 23-26, 2007*
- [30] Y.P.A. Yong, N.J. Hurley, G.C.M. Silverstre, "Single-trial eeg classification for brain-computer interface using wavelet decomposition", *Signal Processing Conference, 2005 13th European Conference 4-8 Sept. 2005*
- [31] R. Chatterjee, T. Bandyopadhyay, "EEG based Motor Imagery Classification using SVM and MLP", DOI: 10.1109/CINE.2016.22 Conference: 2nd International Conference on Computational Intelligence and Networks (CINE), At Bhubaneswar, Volume: 2
- [32] R. Aldea, M. Fira, A. Lazăr, "Classifications of motor imagery tasks using k-nearest neighbors", *Neural Network Applications in Electrical Engineering (NEUREL)*, 2014 12th Symposium on 25-27 Nov. 2014

- [33] [https://en.wikipedia.org/wiki/Nyquist%E2%80%93Shannon\\_sampling\\_theorem](https://en.wikipedia.org/wiki/Nyquist%E2%80%93Shannon_sampling_theorem)
- [34] A. Phinyomark, A. Nuidod, P. Phukpattaranont, C. Limsakul, "Feature Extraction and Reduction of Wavelet Transform Coefficients for EMG Pattern Classification", ISSN 1392 – 1215 ELECTRONICS AND ELECTRICAL ENGINEERING 2012. No. 6(122)
- [35] [http://www.mathworks.com/help/stats/fitcdiscr.html#bt6d86x-2\\_1](http://www.mathworks.com/help/stats/fitcdiscr.html#bt6d86x-2_1)
- [36] [http://www.mathworks.com/help/stats/fitcsvm.html#bt8x\\_mu-1](http://www.mathworks.com/help/stats/fitcsvm.html#bt8x_mu-1)
- [37] <http://www.mathworks.com/help/stats/fitcknn.html#bt6d8vr-3>
- [38] <http://www.mathworks.com/help/nnet/ug/choose-a-multilayer-neural-network-training-function.html>
- [39] [http://portal.tugraz.at/portal/page/portal/TU\\_Graz](http://portal.tugraz.at/portal/page/portal/TU_Graz)
- [40] [http://www.bbc.de/competition/ii/tuebingen\\_desc\\_i.html](http://www.bbc.de/competition/ii/tuebingen_desc_i.html)
- [41] [http://www.bbc.de/competition/ii/albany\\_desc/albany\\_desc\\_ii.html](http://www.bbc.de/competition/ii/albany_desc/albany_desc_ii.html)
- [42] <http://www.bbc.de/competition/>
- [43] [http://scn.ucsd.edu/~arno/fam2data/publicly\\_available\\_EEG\\_data.html](http://scn.ucsd.edu/~arno/fam2data/publicly_available_EEG_data.html)
- [44] <http://www.bsp.brain.riken.jp/~qibin/homepage/Datasets.html>
- [45] <http://bnci-horizon-2020.eu/database/data-sets>
- [46] <http://www.bbc.de/competition/ii/>
- [47] <http://www.gtec.at/>
- [48] [<http://www.consultrsr.net/resources/ref/agcl.htm>]
- [49] [www.designofsignage.com](http://www.designofsignage.com)
- [50] <http://www.mathworks.com/help/nnet/ug/analyze-neural-network-performance-after-training.html>
- [51] B-G. Xu, A-G Song, "Pattern recognition of motor imagery EEG using wavelet transform", J. Biomedical Science and Engineering, 2008, 1, 64-67

