



Πανεπιστήμιο Πειραιώς – Τμήμα Πληροφορικής  
Πρόγραμμα Μεταπτυχιακών Σπουδών  
«Προηγμένα Συστήματα Πληροφορικής»

Μεταπτυχιακή Διατριβή

Τίτλος Διατριβής	<b>(Ελληνικά)</b> <b>Χαρακτηρίζοντας τις διαφορές της δυναμικής λειτουργικής συνδεσιμότητας κατά τη γήρανση ενηλίκων χρησιμοποιώντας προχωρημένες τεχνικές ανάλυσης ηλεκτροεγκεφαλογραφήματος και μηχανικής μάθησης σε κατάσταση ηρεμίας</b> <b>(Αγγλικά)</b> <b>Characterizing the differences in dynamic functional connectivity of aging in adults using advanced EEG analysis techniques and machine learning in resting state</b>
Όνοματεπώνυμο Φοιτητή	<b>Σαλής Χρήστος</b>
Πατρώνυμο	<b>Ηλίας</b>
Αριθμός Μητρώου	<b>ΜΠΣΠ/14079</b>
Επιβλέπων	<b>Γεώργιος Τσιχριτζής, Καθηγητής</b>

Ημερομηνία Παράδοσης **Μήνας Έτος**

---

**Τριμελής Εξεταστική Επιτροπή**

(υπογραφή)

(υπογραφή)

(υπογραφή)

Όνομα Επώνυμο  
Βαθμίδα

Όνομα Επώνυμο  
Βαθμίδα

Όνομα Επώνυμο  
Βαθμίδα

## **Ευχαριστίες**

Αρχικά, θα ήθελα να ευχαριστήσω τον κ. Γεώργιο Τσιχριτζή, για την ανάθεση του θέματος της μεταπτυχιακής διατριβής μου. Επίσης, ένα μεγάλο ευχαριστώ στον κ. Σταύρο Δημητριάδη, όπου χωρίς την καθοδήγηση του, τα σχόλια και τις παρατηρήσεις του δεν θα ήταν δυνατή η περάτωση αυτής της εργασίας. Τέλος δεν ξεχνάω να παραβλέψω τους γονείς μου, για την στήριξη και την συμπαράσταση τους σε όλα τα χρόνια της ζωής μου.

## Περιεχόμενα

<b>Κεφάλαιο 1: Εισαγωγή στο EEG .....</b>	<b>7</b>
<b>1.1 Δραστηριότητες των νευρώνων .....</b>	<b>8</b>
<b>1.2 Δημιουργία του σήματος EEG .....</b>	<b>9</b>
<b>1.3 Ρυθμοί του εγκεφάλου .....</b>	<b>11</b>
<b>1.4 Δειγματοληψία του EEG .....</b>	<b>12</b>
<b>1.5 Γήρανση .....</b>	<b>13</b>
<b>1.6 Μικροκαταστάσεις του EEG .....</b>	<b>13</b>
<b>Κεφάλαιο 2: Σύζευξη συχνοτήτων στο EEG .....</b>	<b>14</b>
<b>2.1 Κλείδωμα φάσης .....</b>	<b>14</b>
<b>2.2 Τύποι συζεύξεων .....</b>	<b>15</b>
2.2.1 Σύζευξη συχνοτήτων φάσης-πλάτους .....	15
2.2.2 Ενδοσύζευξη συχνοτήτων .....	16
<b>2.3 Καθολική και τοπική απόδοση .....</b>	<b>17</b>
<b>2.4 Διάφορες άλλες μετρικές γράφων .....</b>	<b>17</b>
<b>Κεφάλαιο 3: Συνοπτικές τεχνικές γράφων .....</b>	<b>17</b>
<b>3.1 Μη αρνητική παραγοντοποίηση πίνακα .....</b>	<b>18</b>
3.1.1 Αλγόριθμοι επίλυσης του προβλήματος του NNMF .....	18
<b>3.2 Κβαντοποίηση διανυσμάτων – Neural gas .....</b>	<b>19</b>
<b>3.3 Χρήση κατωφλίου στους δυναμικούς γραφούς .....</b>	<b>21</b>
<b>Κεφάλαιο 4: Ταξινομητές .....</b>	<b>22</b>
<b>4.1 Εισαγωγή στην αναγνώριση προτύπων .....</b>	<b>22</b>
<b>4.2 Υπερεπίπεδοι ταξινομητές .....</b>	<b>23</b>
4.2.1 Χώρος καταστάσεων και πυρήνες .....	24
4.2.2 Μηχανές διανυσμάτων υποστήριξης .....	25
<b>4.3 Τεχνητά νευρωνικά δίκτυα .....</b>	<b>25</b>
4.3.1 Extreme learning machine .....	26

<b>Κεφάλαιο 5: Περιγραφή μεθόδων και τεχνικών.....</b>	<b>27</b>
<b>5.1 Πειραματικές HEG καταγραφές .....</b>	<b>27</b>
<b>5.2 Κατασκευή δυναμικών γράφων .....</b>	<b>28</b>
<b>5.3 Μετρικά που χρησιμοποιήθηκαν.....</b>	<b>32</b>
5.3.1 Ποσοστά μεταβάσεων .....	32
5.3.2 Δείκτης πολυπλοκότητας.....	33
5.3.3 Ενδεικτική εντροπία.....	34
5.3.4 Ιστόγραμμα συχνοτήτων .....	35
5.3.5 Μαρκοβιανές αλυσίδες και ποσοστό εντροπίας σε αυτές.....	36
<b>5.4 Περιγραφή επιλογής χαρακτηριστικών.....</b>	<b>37</b>
<b>5.5 Ομαδοποίηση των υποκειμένων.....</b>	<b>38</b>
<b>Κεφάλαιο 6: Αποτελέσματα.....</b>	<b>39</b>
<b>6.1 Παρουσίαση αποτελεσμάτων στη πρόβλεψη της ηλικίας.....</b>	<b>39</b>
<b>6.2 Παρουσίαση αποτελεσμάτων στην ομαδοποίηση των     υποκειμένων στις ηλικιακές ομάδες .....</b>	<b>45</b>
<b>Συμπεράσματα.....</b>	<b>47</b>
<b>Βιβλιογραφία.....</b>	<b>49</b>

## Περίληψη

Η παρούσα μεταπτυχιακή διατριβή πραγματεύεται το πρόβλημα της πρόβλεψη της ηλικίας ενός σύνολου ατόμων μέσω ανάλυσης παλινδρόμησης, καθώς και της ομαδοποίησης αυτών σε δύο ηλικιακές ομάδες, μέσω της μελέτης της λειτουργικής συνδεσιμότητας στο εγκεφαλογράφημα (EEG). Συγκεκριμένα, μελετήθηκε η σύζευξη μεταξύ διαφορετικών συχνοτήτων (Cross frequency coupling, CFC) στα σήματα EEG, ενώ στους γράφους που προέκυψαν εφαρμόστηκαν τεχνικές μείωσης διάστασης και κβαντοποίησης διανυσμάτων, προκειμένου να γίνει πιο εύκολη η επεξεργασία τους. Τέλος, από τους γράφους αυτούς εξήχθησαν διάφορα μετρικά, τα οποία εισήχθησαν ως είσοδοι σε κατάλληλους ταξινομητές, προκειμένου να γίνει εφικτή η πρόβλεψη της ηλικίας και της ομαδοποίησης των υποκειμένων στις ηλικιακές ομάδες.

## Abstract

The current dissertation deals with the problem of age prediction on a set of individuals with the help of regression analysis, and grouping them into two age groups, using the functional connectivity of the electroencephalography (EEG). Specifically, the cross frequency coupling was studied in those EEG signals, while dimension reduction and vector quantization techniques were applied in the graphs that came up, in order to make their processing easier. Finally, several metrics were extracted from those graphs, which were introduced as inputs into appropriate classifiers, in order to make the age prediction and the age grouping feasible.

## Εισαγωγή

Τα δίκτυα λειτουργικής συνδεσιμότητας μπορούν να οριστούν ως η χωροχρονική συσχέτιση μεταξύ διαφόρων περιοχών του εγκεφάλου, τα οποία παρατηρούνται όταν το υποκείμενο εμπλέκεται σε κάποια εργασία, αλλά και όταν δεν κάνει κάποια συγκεκριμένη διεργασία, δηλαδή βρίσκεται σε κατάσταση ηρεμίας. Πρόσφατες μελέτες επικεντρώνονται στην εκτίμηση διαφορών μεταξύ της λειτουργικής συνδεσιμότητας σε διάφορες περιοχές του εγκεφάλου. Πολλές από αυτές χρησιμοποιούν f-MRI σε καταστάσεις ηρεμίας και δείχνουν μεγάλη επαναληψιμότητα σε εξαγωγή χαρακτηριστικών και μοτίβων συνδεσιμότητας σε όλον τον εγκέφαλο. Επίσης, αυτές οι μελέτες τείνουν να χρησιμοποιούν μία πληθώρα από τεχνικές μηχανικής μάθησης, προκειμένου να μελετήσουν τις ομοιότητες στην λειτουργική συνδεσιμότητα μεταξύ των περιοχών του εγκεφάλου. Από τους πιο δημοφιλείς αλγόριθμους μηχανικής μάθησης είναι οι μηχανές διανύσματος υποστήριξης (Support Vector Machines, SVM), εξαιτίας της εύκολης διαχείρισης δεδομένων μεγάλης διάστασης, καθώς και της μεγάλης ακρίβειας που δίνουν τόσο σε ταξινόμηση και πρόβλεψη. Έτσι, σύμφωνα με αυτές τις προηγούμενες μελέτες, οι τεχνικές μηχανικής μάθησης μπορούν να δώσουν νέες πληροφορίες για τη δραστηριότητα του ανθρώπινου εγκεφάλου.

Τα τελευταία χρόνια έχουν γίνει αρκετές έρευνες στη βιβλιογραφία, οι οποίες σχετίζονται με τον διαχωρισμό υποκειμένων σε ηλικιακές ομάδες. Στην εργασία [29] έγινε η χρήση στατικών γράφων για τη ταξινόμηση ατόμων σε παιδιά και ενήλικες, όπου μέσω του ταξινομητή SVM επιτεύχθηκε ποσοστό επιτυχίας ίσο 91%. Επίσης, στο άρθρο [30] έγινε πρόβλεψη της ηλικίας σε ένα σύνολο ατόμων με ηλικίες από 10 ως 70 χρόνια πάλι με χρήση στατικών γράφων, ενώ και σε αυτή την εργασία πραγματοποιήθηκε διαχωρισμός των υποκειμένων σε νέους και μεγάλους. Μετά από την επιλογή διαφόρων χαρακτηριστικών, καθώς και τη χρήση μηχανών υποστήριξης παλινδρόμησης (Support Vector Regression, SVR), επιτεύχθηκε μία αποδεκτή πρόβλεψη ( $R^2 = 0.419$ ), ενώ η κατηγοριοποίηση στις ηλικιακές ομάδες έγινε μέσω του ταξινομητή SVM με ποσοστό επιτυχίας ίσο με 84%.

Στην παρούσα μεταπτυχιακή διατριβή εξετάζεται η λειτουργική συνδεσιμότητα με τη χρήση δυναμικών γράφων σε σήματα εγκεφαλογραφήματος (EEG) με ένα σύνολο από 94 υποκείμενα ηλικιών από 19 ως 67, όταν αυτά βρίσκονται στην κατάσταση ηρεμίας, με σκοπό την πρόβλεψη των ηλικιών τους, καθώς και την κατηγοριοποίησή τους σε νέους και μεγάλους. Στην ανάλυση της λειτουργικής συνδεσιμότητας μοντελοποιούνται τόσο οι αλληλεπιδράσεις μεταξύ των συχνότητων στον ίδιο αισθητήρα (intra frequency coupling), όσο και μεταξύ διαφορετικών αισθητήρων. Έπειτα, προκύπτουν οι μικροκαταστάσεις από την καθολική απόδοση των δυναμικών γράφων, με τιμές από ένα συγκεκριμένο βιβλίο κωδίκων (codebook). Έτσι, προκύπτει μια χρονοσειρά συμβόλων, όπου σε κάθε σύμβολο αντιστοιχείται μία τιμή από το βιβλίο κωδίκων. Σε αυτή τη χρονοσειρά συμβόλων, καθώς και στους δυναμικούς γράφους εξάγονται διάφορα χαρακτηριστικά και επιλέγονται αυτά που συνεισφέρουν περισσότερο στην πρόβλεψη της ηλικίας μέσω ανάλυσης παλινδρόμησης, καθώς και στην κατηγοριοποίηση των υποκειμένων στις ηλικιακές ομάδες.


Στο κεφάλαιο 1, γίνεται μια σύντομη εισαγωγή για τους νευρώνες και τους ρυθμούς του εγκεφάλου. Επίσης, εξηγείται η έννοια του σήματος EEG και ο τρόπος δειγματοληψίας και εξαγωγής του. Στο κεφάλαιο 2, περιγράφεται η σύζευξη μεταξύ διαφορετικών συχνότητων του εγκεφάλου, ο τρόπος που μπορεί να μετρηθεί αυτή η σύζευξη, ενώ παρουσιάζονται και κάποιες μετρικές γράφων. Στο κεφάλαιο 3, αναλύονται οι τεχνικές της μη αρνητικής παραγοντοποίησης πίνακα (Non negative matrix factorization NMF) και της κβαντοποίησης διανυσμάτων (vector quantization - neural gas), οι οποίες χρησιμοποιήθηκαν στους δυναμικούς γράφους. Επιπρόσθετα, εξηγείται το πώς γίνεται η καταφλίωση στους δυναμικούς γράφους. Στο κεφάλαιο 4, γίνεται μία σύντομη εισαγωγή στη μηχανική μάθηση, ενώ περιγράφονται η λειτουργία των ταξινομητών που χρησιμοποιήθηκαν. Στο κεφάλαιο 5 εξηγείται αναλυτικά το σύνολο δεδομένων που χρησιμοποιήθηκε, η κατασκευή των δυναμικών γράφων και η εφαρμογή της μεθόδου NMF-VQ στους δυναμικούς γράφους. Επίσης αναλύεται ο τρόπος εξαγωγής και επιλογής χαρακτηριστικών για τα πρόβλημα της πρόβλεψης ηλικίας και κατηγοριοποίησης των υποκειμένων. Τέλος, στο κεφάλαιο 6 παρουσιάζονται και αναλύονται τα αποτελέσματα που εξήχθησαν από την επίλυση των δύο προβλημάτων.

## Κεφάλαιο 1: Εισαγωγή στο EEG

### 1.1 Δραστηριότητες των νευρώνων

Το κεντρικό νευρικό σύστημα αποτελείται από νευρικά και νευρογλοιακά κύτταρα, τα οποία βρίσκονται κοντά στους νευρώνες. Κάθε νευρικό κύτταρο αποτελείται από άξονες, δενδρίτες και κυτταρικά σώματα. Ένας άξονας είναι ένας μεγάλος "κύλινδρος", οποίος μεταδίδει έναν ηλεκτρικό παλμό και μπορεί να είναι αρκετά μέτρα σε μήκος. Επιπρόσθετα, ο δενδρίτης είναι συνδεδεμένος είτε στους άξονες είτε στους δενδρίτες άλλων κυττάρων και μπορεί να αναμεταδίδει ή να λαμβάνει παλμούς από άλλους νευρώνες. Γενικά, τα νευρικά κύτταρα ανταποκρίνονται σε ερεθίσματα, ενώ μπορούν να μεταβιβάσουν πληροφορίες σε μεγάλες αποστάσεις. Όσον αφορά το σώμα ενός νευρικού κυττάρου, αυτό έχει έναν ενιαίο πυρήνα και περιέχει το μεγαλύτερο μέρος του μεταβολισμού ενός κυττάρου, ειδικά αυτών που σχετίζονται με τη σύνθεση πρωτεϊνών. Οι πρωτεΐνες που δημιουργούνται στο σώμα ενός κυττάρου μεταφέρονται σε άλλα μέρη του νευρώνα.

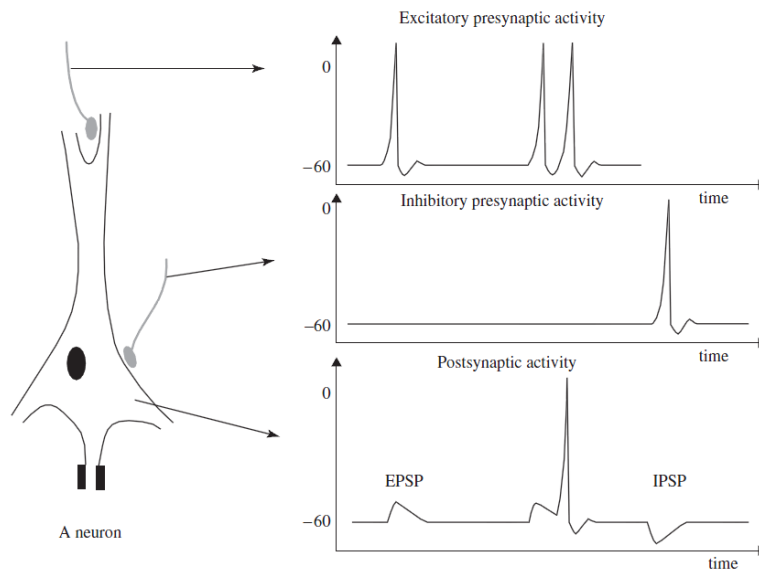
Οι δραστηριότητες ενός νευρικού συστήματος σχετίζονται κυρίως με τα συναπτικά ρεύματα που μεταφέρονται μεταξύ των αξόνων και των δενδριτών ή μεταξύ των δενδριτών και των δενδριτών των κυττάρων. Ένα δυναμικό 60-70 mV με αρνητική πόλωση μπορεί να καταγραφεί κάτω από τη μεμβράνη ενός κυτταρικού σώματος. Αυτό το δυναμικό αλλάζει, ανάλογα με τις εναλλαγές των συναπτικών δραστηριοτήτων. Αν ένα δυναμικό δράσης ταξιδεύει σε μία σύναψη ενός νευρώνα, ένα διεγερτικό μετασυναπτικό δυναμικό (excitatory postsynaptic potential, EPSP) θα εμφανιστεί σε αυτόν τον νευρώνα. Σε περίπτωση που δύο δυναμικά δράσης ταξιδεύουν στον ίδιο νευρώνα, θα υπάρχει συνάθροιση των δύο EPSPs, με αποτέλεσμα να δημιουργηθεί ένα νέο δυναμικό στον μετασυναπτικό νευρώνα, δεδομένου ότι υπάρχει ένα συγκεκριμένο κατώφλι στο δυναμικό της μεμβράνης. Αν ο νευρώνας καταλήγει σε μια ανασταλτική σύναψη, τότε εμφανίζεται υπερπόλωση, με αποτέλεσμα να εμφανιστεί ένα ανασταλτικό μετασυναπτικό δυναμικό (inhibitory postsynaptic potential, IPSP). Στην εικόνα 1.2 φαίνονται αυτά τα δυναμικά.



**Εικόνα 1.1: Νευρώνες μεταδίδουν πληροφορίες σε άλλους νευρώνες. Η πληροφορία περνάει από τον άξονα του προσυναπτικού νευρώνα στους δενδρίτες του μετασυναπτικού νευρώνα [1].**

Μετά την ενεργοποίηση ενός IPSP υπάρχει μια υπερχείλιση των κατιόντων από ένα νευρικό κύτταρο ή μια εισροή ανιόντων σε ένα νευρικό κύτταρο. Αυτή η ροή δημιουργεί μια αλλαγή στο δυναμικό της μεμβράνης ενός νευρικού κυττάρου. Επίσης, πρωτεύοντα διαμεμβρανικά ρεύματα δημιουργούν δευτερογενή εσωτερικά ρεύματα κατά μήκος των κυτταρικών μεμβρανών στον ενδοκυτταρικό και εξωκυτταρικό χώρο. Η ποσότητα αυτών των ρευμάτων που ρέουν μέσω του εξωκυτταρικού χώρου είναι άμεσα υπεύθυνη για τη δημιουργία δυναμικών. Τα δυναμικά που έχουν συνήθως συχνότητα κάτω από 100 Hz και δεν παρουσιάζουν αλλαγή στη μέση τιμή του σήματος ονομάζονται εγκεφαλογραφήματα (electroencephalogram, EEG). Αντίθετα, τα δυναμικά που έχουν μικρές διακυμάνσεις στις μέσες τιμές των σημάτων ονομάζονται DC (Direct Current). Πολλές φορές, παρατηρείται συχνά ένας συνδυασμός στα δυναμικά EEG και DC, ο οποίος οδηγεί σε ανωμαλίες του εγκεφάλου, όπως επιληψία.






**Εικόνα 1.2: Τα δυναμικό στη μεμβράνη ενός νευρώνα [1]**

### 1.2 Δημιουργία του σήματος EEG

Ένα σήμα EEG είναι μια μέτρηση των ρευμάτων που ρέουν κατά τη διάρκεια της διέγερσης των συνάψεων των πυραμδικών δενδριτών στον φλοιό του εγκεφάλου. Όταν ενεργοποιούνται οι νευρώνες, τα συναπτικά ρεύματα παράγονται μέσα στους δενδρίτες. Αυτά τα ρεύματα δημιουργούν ένα μαγνητικό πεδίο, το οποίο καταγράφεται από τις συσκευές ηλεκτρομυογραφίας (EMG), καθώς και ένα ηλεκτρικό πεδίο, που καταγράφεται από μηχανήματα EEG.

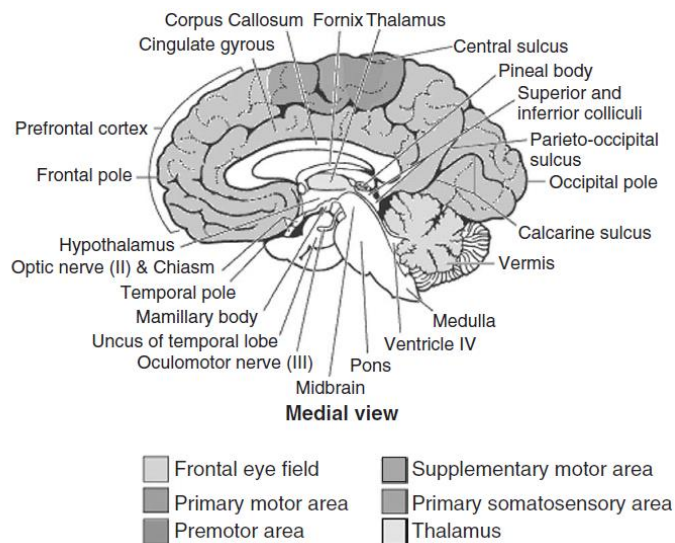
Το ανθρώπινο κεφάλι περιλαμβάνεται από διαφορετικά επίπεδα, όπως το δέρμα, το κρανίο και τον εγκέφαλο (εικόνα 1.3). Το κρανίο αποσβένει τα σήματα εκατό φορές περισσότερο από ότι ο μαλακός ιστός, ενώ το μεγαλύτερο μέρος του θορύβου δημιουργείται είτε από τον εγκέφαλο (εσωτερικός θόρυβος), είτε γύρω από το κρανίο (εξωτερικός θόρυβος). Για αυτό τον λόγο, μόνο ένας μεγάλος αριθμός ενεργών νευρώνων μπορεί να δημιουργήσει αρκετό δυναμικό, ώστε να μπορεί να καταγραφεί από τα ηλεκτρόδια, τα οποία είναι τοποθετημένα γύρω από το δέρμα του κεφαλιού. Έπειτα, το πλάτος αυτών των σημάτων αυξάνεται αρκετά, κυρίως για σκοπούς απεικόνισης.



**Εικόνα 1.3: Τα τρία επίπεδα του εγκεφάλου μαζί με το πάχος και την αντίσταση του κάθε επιπέδου [1]**

Περίπου  $10^{11}$  νευρώνες αναπτύσσονται, όταν το κεντρικό νευρικό σύστημα έχει δημιουργηθεί και λειτουργεί μετά τη γέννα. Αυτό σημαίνει ότι υπάρχουν  $10^4$  νευρώνες ανά κυβικό χιλιοστό. Οι νευρώνες είναι διασυνδεδεμένοι στα νευρωνικά δίκτυα, μέσω των συνάψεων. Ο αριθμός των συνάψεων αυξάνεται όσο μεγαλώνει η ηλικία, ενώ ο αριθμός των νευρώνων μειώνεται.

Από ανατομική άποψης, ο εγκέφαλος χωρίζεται σε τρία μέρη : το κύριο μέρος του εγκεφάλου (cerebrum), τη παρεγκεφαλίδα (cerebellum) και το εγκεφαλικό στέλεχος (brain stem). Το κύριο μέρος του εγκεφάλου αποτελείται από τον αριστερό και τον δεξί λοβό, καθώς και από περίπλοκες επιφάνειες, οι οποίες αποτελούν τον εγκεφαλικό φλοιό. Επίσης, το κύριο μέρος του εγκεφάλου περιλαμβάνει τις περιοχές που σχετίζονται με την κίνηση, επίγνωση συνείδησης της αίσθησης και έκφραση των συναισθημάτων και της συμπεριφοράς. Όσον αφορά, την παρεγκεφαλίδα, αυτή ρυθμίζει εκούσια τις κινήσεις των μυών, καθώς και τη διατήρηση της ισορροπίας. Τέλος, το εγκεφαλικό στέλεχος ρυθμίζει ακούσια λειτουργίες όπως αναπνοή, ρύθμιση καρδιάς, βιορυθμούς καθώς και νευροορμόνες και διάφορα ορμονικά μέρη.



**Εικόνα 1.4: Διαγραμματική αναπαράσταση των σημαντικών περιοχών του εγκεφάλου [1]**

Βασίζοντας στα παραπάνω, είναι ξεκάθαρο ότι το EEG ανοίγει τον δρόμο στη διάγνωση διαφόρων νευρολογικών και άλλων ανωμαλιών στο ανθρώπινο σώμα. Το σήμα EEG, μπορεί να χρησιμοποιηθεί για τη διάγνωση των παρακάτω ασθενειών:

- Παρακολούθηση εγρήγορσης, κώμα και θάνατο εγκεφάλου
- Εντοπισμός περιοχών στον εγκέφαλο, στις οποίες υπέστη ζημιά, μετά από τραυματισμό στο κεφάλι, χτύπημα ή εξαιτίας κάποιου όγκου
- Δοκιμή προσαγωγών οδών.
- Παρακολούθηση γνωστικής εμπλοκής
- Παραγωγή κατάστασης βιοανάδρασης
- Έλεγχος βάθους αναισθησίας
- Διερεύνηση επιληψίας και εντοπισμός της προέλευσης της
- Δοκιμή της επίδρασης φαρμάκων κατά της επιληψίας
- Βοήθεια στην πειραματική εκτομή φλοιού στις περιοχές που σχετίζονται με την επιληψία
- Παρακολούθηση της ανάπτυξης του εγκεφάλου
- Διερεύνηση ανωμαλιών ύπνου και φυσιολογίας
- Διερεύνηση ψυχικών διαταραχών
- Παροχή ενός συστήματος καταγραφής υβριδικών δεδομένων μαζί με άλλες μορφές απεικόνισης.

### 1.3 Ρυθμοί του εγκεφάλου

Πολλές διαταραχές του εγκεφάλου μπορούν να διαγνωστούν με την οπτική εξέταση των σημάτων EEG. Στους υγιείς ενήλικες, τα πλάτη και οι συχνότητες αυτών των σημάτων αλλάζουν σε κάθε κατάσταση ενός ατόμου, π.χ. στον ύπνο ή στην εγρήγορση. Επίσης, τα χαρακτηριστικά τους αλλάζουν με την ηλικία. Συνολικά, υπάρχουν πέντε διαφορετικά εγκεφαλικά σήματα τα οποία διακρίνονται από τις διαφορετικές περιοχές συχνοτήτων τους. Αυτές οι συχνότητες ονομάζονται : άλφα ( $\alpha$ ), θήτα ( $\theta$ ), δέλτα ( $\delta$ ) και γάμμα ( $\gamma$ ).

Τα σήματα δέλτα βρίσκονται στις συχνότητες μεταξύ 0.5 και 4 Hz και σχετίζονται κυρίως με τον βαθύ ύπνο, ενώ μπορεί μερικές φορές να εμφανίζονται και σε καταστάσεις εγρήγορσης. Είναι πολύ εύκολο να γίνει περιπλοκή μεταξύ των σημάτων που παράγονται με την κίνηση των μεγάλων μυών, του λαιμού και του σαγονιού, με την απόκριση των σημάτων δέλτα. Αυτό κυρίως συμβαίνει επειδή οι μύες είναι κοντά στην επιφάνεια του δέρματος και παράγουν σήματα με μεγάλα πλάτη, ενώ αντίθετα το επιθυμητό σήμα που πρέπει να γίνει καταγραφή, παράγεται μέσα στον εγκέφαλο και αποσβένει σημαντικά καθώς διέρχεται από το κρανίο. Παρόλο αυτά, με την εφαρμογή κατάλληλων τεχνικών επεξεργασίας σήματος στο EEG, είναι πολύ εύκολο να παρατηρηθεί η απόκριση που δημιουργείται από τη κίνηση των μυών.

Τα σήματα θήτα βρίσκονται στο εύρος των συχνοτήτων 4-7.5 Hz, ενώ έχουν συσχετισθεί κυρίως με το ασυνείδητο, τη δημιουργική έμπνευση καθώς και τον διαλογισμό. Επίσης, παίζουν σημαντικό ρόλο στη νηπιακή και στη παιδική ηλικία. Όσον αφορά στους ενήλικες, μεγάλες περιοχές του EEG στις οποίες εμφανίζεται η συχνότητα θήτα είναι μη φυσιολογικές και προκαλούνται από διάφορα παθολογικά προβλήματα.


Επιπρόσθετα, τα σήματα άλφα εμφανίζονται στο οπίσθιο μισό του κεφαλιού και συνήθως βρίσκονται πάνω από την ινιακή περιοχή. Επίσης, μπορούν να ανιχνευθούν σε όλα τα μέρη των οπίσθιων λοβών του εγκεφάλου. Η συχνότητα τους βρίσκεται εντός της περιοχής των 8-13 Hz και συνήθως η κυματομορφή τους είναι ημιτονοειδής. Οι κυματομορφές άλφα συνήθως εμφανίζονται όταν ο εγκέφαλος βρίσκεται σε καταστάσεις χαλάρωσης, χωρίς να υπάρχει κάποια κατάσταση προσοχής ή συγκέντρωσης. Ο ρυθμός άλφα είναι ο πιο σημαντικός σε όλο το φάσμα συχνοτήτων της δραστηριότητας του εγκεφάλου και πιθανώς καλύπτει ένα μεγαλύτερο εύρος από όσο έχει ήδη αναφερθεί. Επίσης, μία κυματομορφή άλφα έχει μεγαλύτερο πλάτος στις ινιακές περιοχές, με τιμή που είναι λιγότερη από 50  $\mu$ V. Η προέλευση και η φυσιολογική σημασία των σημάτων άλφα είναι ακόμα άγνωστες και πρέπει να γίνει περαιτέρω έρευνα, προκειμένου να γίνει κατανοητό πώς αυτές οι συχνότητες προέρχονται από τα φλοιώδη κύτταρα.

Η κυματομορφή βήτα είναι η ηλεκτρική δραστηριότητα του εγκεφάλου, η οποία κυμαίνεται μεταξύ του εύρους 14-26 Hz. Συνήθως σχετίζεται με δραστηριότητες του εγκεφάλου όπως η ενεργή σκέψη, η ενεργή προσοχή, επικέντρωση στον έξω κόσμο ή στην επίλυση συγκεκριμένων προβλημάτων και εμφανίζεται στους φυσιολογικούς ενήλικες. Μία κυματομορφή βήτα μπορεί να αποκτηθεί όταν ο άνθρωπος είναι σε κατάσταση πανικού. Επίσης, τα σήματα βήτα εντοπίζονται κυρίως στις μπροστινές και κεντρικές περιοχές του εγκεφάλου.

Οι συχνότητες μεγαλύτερες των 30 Hz (κυρίως ως και 45 Hz) αντιστοιχούν στο εύρος συχνοτήτων γάμμα. Παρόλο αυτά, τα πλάτη αυτών των ρυθμών είναι πάρα πολύ μικρά, ενώ η εμφάνισή τους είναι σπάνια. Ο ρυθμός γάμμα έχει επίσης αποδειχθεί ότι είναι μια καλή ένδειξη του event-related synchronization (ERS) του εγκεφάλου, ενώ μπορεί να χρησιμοποιηθεί για να δείξει ποιες περιοχές του εγκεφάλου σχετίζονται με τη κίνηση του αριστερού δείκτη του χεριού, καθώς και την κίνηση των δακτύλων του δεξιού ποδιού. Στην εικόνα 1.5 φαίνονται οι κύριοι ρυθμοί του εγκεφάλου με τα συνήθη πλάτη που έχουν. Γενικά, το σήμα EEG θα μπορούσε να χαρακτηριστεί ως η προβολή των νευρωνικών δραστηριοτήτων, οι οποίες αποσβένουν από τις λεπτομήνιγγες, το εγκεφαλονωτιαίο υγρό, τη σκληρή μήνιγγα των οστών, καθώς και το τριχωτό της κεφαλής. Επίσης, υπάρχουν και άλλοι ρυθμοί, όπως:

- Ο ρυθμός φι ( $\phi$ ) (για συχνότητες μικρότερες 4 Hz), ο οποίος εμφανίζεται όταν γίνεται κλείσιμο του ματιού μέσα σε δύο δευτερόλεπτα.
- Ο ρυθμός κάπα ( $k$ ), οποίος μοιάζει πολύ με τον ρυθμό alpha. Θεωρείται ότι είναι το αποτέλεσμα διακριτών πλευρικών ταλαντώσεων των βολβών των ματιών. Συνήθως, το σήμα αυτό είναι θόρυβος.

- Οι άτρακτοι ύπνου (επίσης ονομάζονται και δραστηριότητα sigma ( $\sigma$ )), οι οποίοι βρίσκονται στο εύρος συχνοτήτων 11-15 Hz.
- Ο ρυθμός ταφ ( $\tau$ ), οποίος αναπαριστά τη δραστηριότητα alpha στη προσωρινή περιοχή.
- Ο ρυθμός λάμδα ( $\lambda$ ), ο οποίος εμφανίζεται στους αφυπνισμένους ασθενείς, αλλά όχι και τόσο συχνά. Είναι απότομες μεταβάσεις που συμβαίνουν στην ινιακή περιοχή της κεφαλής, σε ασθενείς που περπατούν κατά τη διάρκεια μιας οπτικής εξερεύνησης. Οι τιμές αυτού του ρυθμού είναι θετικές, ενώ το πλάτος κυμαίνεται γενικά κάτω από τα 90  $\mu\text{V}$ .



**Εικόνα 1.5: Οι τέσσερις κύριοι ρυθμοί του εγκεφάλου, από τις υψηλές στις χαμηλές συχνότητες [1]**

#### 1.4 Δειγματοληψία του EEG

Τα πιο σύγχρονα συστήματα EEG περιλαμβάνουν έναν αριθμό από λεπτά ηλεκτρόδια, καθώς και από ένα σύνολο διαφορικών ενισχυτών (έναν για κάθε κανάλι) ακολουθούμενοι μετά από φίλτρα. Αρχικά, τα σήματα EEG από πολλά κανάλια ηλεκτροδίων, μπορούσαν να αναπαρασταθούν σε ένα απλό χαρτί με πλέγμα. Όμως, προκειμένου να μπορεί να γίνει η επεξεργασία αυτών των σημάτων, έπρεπε να γίνει ψηφιοποίηση τους. Αυτό απαιτούσε δειγματοληψία, κβάντιση και κωδικοποίηση των σημάτων. Τα ψηφιακά συστήματα, τα οποία μπορούν να ψηφιοποιήσουν τα σήματα EEG, επιτρέπουν τη ρυθμίσεις μεταβλητών, διεγέρσεων, καθώς και την ρύθμιση της συχνότητας δειγματοληψίας, ενώ κάποια είναι εξοπλισμένα και με εργαλεία επεξεργασίας σήματος.

Η μετατροπή από αναλογικό σε ψηφιακό EEG γίνεται μέσω πολυκαναλικών αναλογικών σε ψηφιακών μετατροπέων. Ευτυχώς, το ενεργό εύρος ζώνης για τα σήματα EEG περιορίζεται περίπου στα 100 Hz. Έτσι, σύμφωνα με το κριτήριο του Nyquist, η ελάχιστη συχνότητα δειγματοληψίας, η οποία είναι ίση με 200 δείγματα/sec, είναι συνήθως αρκετή για τη δειγματοληψία του σήματος. Σε μερικές εφαρμογές, όπου απαιτείται υψηλότερη ανάλυση στα σήματα, προκειμένου να γίνει η αναπαράσταση των δραστηριοτήτων του εγκεφάλου, χρησιμοποιούνται συχνότητες δειγματοληψίας ως και 2000 δείγματα/sec. Για να διατηρηθούν οι διαγνωστικές πληροφορίες, συνήθως η κβάντιση των σημάτων EEG είναι αρκετά καλή. Η αναπαράσταση του κάθε δείγματος, έως και 16 bits, είναι αρκετά δημοφιλής για τα συστήματα καταγραφής EEG.

Ο τύπος των ηλεκτροδίων για την καταγραφή του EEG, καθώς και η σωστή λειτουργία τους είναι αρκετά σημαντική για την απόκτηση δεδομένων υψηλής ποιότητας. Διαφορετικοί τύποι χρησιμοποιούνται συχνά στα συστήματα καταγραφής EEG, όπως :

- Αναλώσιμα ηλεκτρόδια
- Επαναχρησιμοποιούμενα ηλεκτρόδια δίσκου
- Κορδέλες και καλύμματα ηλεκτροδίων
- Ηλεκτρόδια με χρήση αλατόνευρου
- Ηλεκτρόδια βελόνας



**Εικόνα 1.6: Επαναχρησιμοποιούμενα ηλεκτρόδια δίσκου [2]**

## 1.5 Γήρανση

Η διαδικασία της γήρανσης επηρεάζει τη δραστηριότητα του εγκεφάλου στο ξύπνημα και στον ύπνο, καθώς την απόκριση του σε διάφορα ερεθίσματα. Οι αλλαγές προκύπτουν από τη μείωση των αριθμών των νευρώνων και από τη αλλαγή της φυσιολογίας του εγκεφάλου. Επίσης, έχει παρατηρηθεί μείωση της εμφάνισης της alpha συχνότητας στους ηλικιωμένους, η οποία οδηγεί σε μείωση της απόκρισης και της αντιδραστικότητας. Αυτή η μείωση της εγκεφαλικής δραστηριότητας σχετίζεται με κάποιον τρόπο με την επιβράδυνση στα κύματα theta και delta.

Όσον αφορά το σήμα EEG στον ύπνο, οι ενήλικες μεγαλύτερης ηλικίας τίθενται σε υπνηλία, με το πλάτος του EEG να μειώνεται σταδιακά. Μετά την ηλικία των εξήντα, υπάρχει σημαντική μείωση στο πλάτος του EEG στη φάση NREM (Non-rapid eye movement, μη ταχεία κίνηση των ματιών). Επίσης, υπάρχει μεγάλη αλλαγή στη φάση REM (Rapid eye movement, ταχεία κίνηση ματιού), στην οποία η διάρκεια της μειώνεται κατά τη διάρκεια της νύχτας, ενώ εμφανίζεται μια σημαντική αύξηση της διαταραχής του ύπνου.

Γενικά το EEG είναι ένα πολύτιμο διαγνωστικό εργαλείο το οποίο βοηθάει στη διαφοροποίηση μεταξύ των οργανικών συνδρόμων του εγκεφάλου (organic brain syndromes, OBC) και των λειτουργικών ψυχιατρικών διαταραχών, ενώ παίζει σημαντικό ρόλο στην αξιολόγηση της φυσικής και της παθολογικής γήρανσης. Η αυτόματα ανάλυση του EEG κατά τη διάρκεια του ύπνου και της αγρυπνίας μπορεί να παρέχει μια καλύτερη αντίθεση στα δεδομένα, καθώς και ένα δυνατό διαγνωστικό εργαλείο.


## 1.6 Μικροκαταστάσεις του EEG

Η ανάγκη του ανθρώπου για αλληλεπίδραση με το περιβάλλον, απαιτεί μεταβολές στις καταστάσεις του εγκεφάλου, οι οποίες μπορούν να εναλλάσσονται σε χιλιοστά του δευτερολέπτου. Αυτές οι καταστάσεις αλλάζουν με μη συνεχή τρόπο, π.χ. η κατάσταση της εγρήγορσης και η ξαφνική εξαφάνιση της με την έναρξη του ύπνου. Τέτοιες αλλαγές της κατάστασης σχετίζονται με μεταβολές στην ηλεκτρική δραστηριότητα του εγκεφάλου, οι οποίες φαίνονται στο σήμα EEG. Έτσι, η ηλεκτρική δραστηριότητα του εγκεφάλου μπορεί να αναλυθεί σε μικροκαταστάσεις (microstates), οι οποίες διαρκούν κλάσματα του δευτερολέπτου, χαρακτηριζόμενες από σταθερές χωρικές κατανομές. Επειδή αυτές οι χωρικές κατανομές του ηλεκτρικού δυναμικού προκύπτουν από τις διαφορετικές κατανομές της ηλεκτρικής δραστηριότητας



των νευρώνων στον εγκέφαλο, μπορεί να υποτεθεί ότι αυτές οι μικροκαταστάσεις ενσωματώνουν διάφορες λειτουργίες του εγκεφάλου. Συνολικά υπάρχουν τέσσερις κατηγορίες μικροκαταστάσεων, οι οποίες διαχωρίζονται από την κατεύθυνση του δυναμικού στις περιοχές του εγκεφάλου :

- Κλάση A: δεξιό μετωπιαίο προς αριστερό μετωπιαίο
- Κλάση B: αριστερό μετωπιαίο προς δεξί μετωπιαίο
- Κλάση C: εμπρόσθιο προς ινιακό
- Κλάση D: περισσότερη δραστηριότητα προς τη μετωπιαία περιοχή και λιγότερη δραστηριότητα στην ινιακή περιοχή από ότι στη κλάση C



**Εικόνα 1.7: Οι τέσσερις βασικές κλάσεις μικροκαταστάσεων**

## Κεφάλαιο 2: Σύζευξη συχνότητων στο EEG

Ένα κεντρικό ερώτημα στον τομέα της γνωστικής νευροεπιστήμης είναι το πώς οι γνωστικές λειτουργίες (cognitive functions) εξαρτώνται από τη συντονισμένη και ολοκληρωμένη δραστηριότητα των ευρέων διανεμημένων περιοχών του εγκεφάλου. Υπάρχει μια ισχυρή γνώμη, η οποία υποστηρίζει ότι απαιτείται η γνώση των συνδεδεμένων περιοχών του εγκεφάλου, προκειμένου να γίνει κατανοητή η λειτουργία του. Για να γίνει όμως κάτι τέτοιο θα πρέπει να είναι γνωστό το πώς οι λειτουργικές αλληλεπιδράσεις αυτών των περιοχών λαμβάνουν χώρα, καθώς και με ποιον τρόπο μπορούν αυτές να εκτιμηθούν. Προκειμένου να υπάρχει απάντηση σε κάτι τέτοιο, χρησιμοποιείται η ιδέα της λειτουργικής συνδεσιμότητας (functional connectivity), η οποία αναφέρεται ως οι γραμμικές ή μη γραμμικές στατιστικές εξαρτήσεις μεταξύ των χρονοσειρών των φυσιολογικών σημάτων, όπου είναι καταγεγραμμένες από διαφορετικές περιοχές του εγκεφάλου.

Οι αλληλεπιδράσεις του εγκεφάλου μπορούν αναπαρασταθούν με τη χρήση σταθμισμένων γράφων, όπου τα βάρη των ακμών δείχνουν το πόσο δύο περιοχές σχετίζονται μεταξύ τους. Για να οριστούν τα αντίστοιχα βάρη χρειάζεται να υπάρχει ένας πίνακας συσχετίσεων, ο οποίος δείχνει τη συσχέτιση μεταξύ των σημάτων που είναι καταγεγραμμένα από τα διαφορετικά ηλεκτρόδια. Ο πίνακας συσχετίσεων ορίζεται ως  $w_{ij}$ , όπου τα  $i$  και  $j$  δείχνουν τους κόμβους του γράφου, δηλαδή τα ηλεκτρόδια που κάνουν τη δειγματοληψία του EEG. Για να καθοριστούν όμως οι τιμές των ακμών του πίνακα  $w$  χρησιμοποιείται σαν μετρικό ο δείκτης υστέρησης φάσης (phase lag index, PLI). Το PLI είναι ένα μέτρο της ασυμμετρίας της κατανομής της διαφοράς φάσης μεταξύ δύο σημάτων, αντανακλά στη συνέπεια με την οποία ένα σήμα προηγείται ή καθυστερεί σε φάση σε σχέση με ένα άλλο.

### 2.1 Κλειδωμα φάσης

Πέρα από το PLI, ένα άλλο μέτρο το οποίο χρησιμοποιείται στον υπολογισμό της λειτουργικής συνδεσιμότητας είναι το κλειδωμα φάσης (phase locking value, PLV). Ουσιαστικά, το κλειδωμα φάσης δείχνει το πόσο μπορούν δύο σήματα να διατηρούν τη διαφορά φάσης τους σταθερή ως προς τον χρόνο. Παρακάτω φαίνονται μερικά από τα χαρακτηριστικά του PLV [3] :

1. Το PLV αλλάζει τιμή ως προς τον χρόνο. Αυτό σημαίνει ότι για κάθε χρονική στιγμή στο σήμα EEG, μπορεί να εξαχθεί ένας πίνακας συσχετίσεων. Έτσι, το PLV μπορεί να χρησιμοποιηθεί για την ανίχνευση αλλαγών στη συνδεσιμότητα του γράφου (δυναμικός γράφος).
2. Όπως και στο PLI, έτσι και στο PLV, υπάρχει μία τιμή για κάθε ζεύγος ηλεκτροδίων. Για παράδειγμα, αν υπάρχουν  $k$  συνολικά ηλεκτρόδια, τότε θα υπάρχουν  $k(k-1)/2$  διαφορετικές τιμές για μία χρονική στιγμή.

Προκειμένου να υπολογιστεί το PLV θα πρέπει να γίνουν τα παρακάτω στάδια :

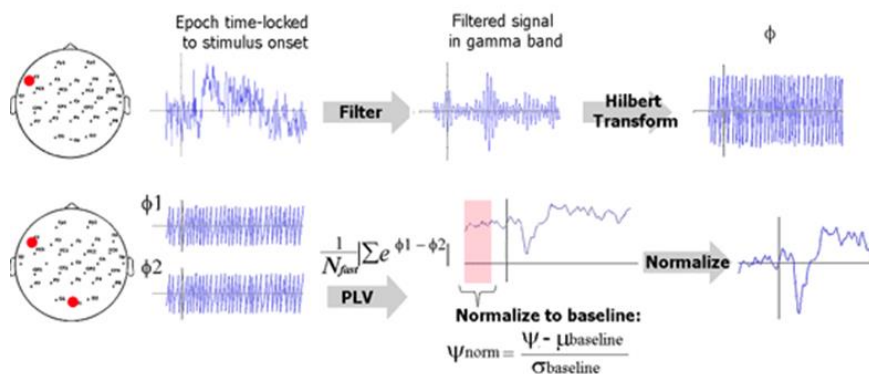
1. Φιλτράρισμα του EEG. Αρχικά το σήμα EEG φιλτράρεται στο επιθυμητό εύρος συχνοτήτων, π.χ. στη συχνότητα gamma (35-45 Hz).
2. Μετασχηματισμός Hilbert. Αυτό το βήμα χρησιμοποιείται για να γίνει μια ποσοτικοποίηση της αύξησης ή της μείωσης του πλάτους ενός EEG σήματος. Ο μετασχηματισμός Hilbert μπορεί να χρησιμοποιηθεί για τον υπολογισμό του στιγμιαίου πλάτους, καθώς και της στιγμιαίας φάσης. Το εύρος των τιμών της φάσης είναι από  $-\pi$  ως  $\pi$ .
3. Υπολογισμός του PLV. Το PLV μπορεί να υπολογιστεί από τη παρακάτω εξίσωση [28] :

$$PLV_t = \frac{|\sum_{n=1}^N e^{j[\varphi_1(t,n) - \varphi_2(t,n)]}|}{N} \quad (2.1)$$

όπου  $N$  είναι ο αριθμός των συνολικών trials (δηλαδή το πόσες φορές έχει γίνει δειγματοληψία του EEG),  $\varphi_1$  και  $\varphi_2$  είναι οι φάσεις των EEG για δύο ηλεκτρόδια αντίστοιχα,  $t$  είναι η χρονική στιγμή στην οποία αναφέρεται η τιμή του PLV και  $n$  είναι το αντίστοιχο trial.

4. Κανονικοποίηση. Η τιμή του PLV κυμαίνεται εξ ορισμού μεταξύ 0 και 1, όπου το 0 δείχνει ότι δεν υπάρχει καμία συμφωνία στις φάσεις των δύο σημάτων, ενώ το 1 δείχνει ότι υπάρχει απόλυτη συμφωνία.

Στην εικόνα 2.1 φαίνονται τα στάδια του υπολογισμού του PLV.



**Εικόνα 2.1:** Παράδειγμα υπολογισμού του PLV

## 2.2 Τύποι συζεύξεων

Ένας αυξανόμενος αριθμός από μελέτες δείχνει ότι η σύζευξη μεταξύ διαφορετικών συχνοτήτων (cross-frequency coupling, CFC) στο EEG (δηλαδή η εξάρτηση των σημάτων υψηλών συχνοτήτων από αυτές των χαμηλών), μπορεί να παίζει σημαντικό ρόλο στην επεξεργασία του [4]. Εφόσον διάφορες περιοχές του εγκεφάλου λειτουργούν σε χαμηλές συχνότητες και άλλες λειτουργούν σε υψηλές, η σύζευξη μεταξύ διαφορετικών συχνοτήτων θα βοηθούσε αρκετά στον εύκολο συντονισμό της νευρικής δραστηριότητας στον χώρο και στον χρόνο ταυτόχρονα.

### 2.2.1 Σύζευξη συχνοτήτων φάσης-πλάτους

Έχει αναφερθεί ότι η σύζευξη διαφορετικών συχνοτήτων φάσης και πλάτους (phase-amplitude CFC), όπου η φάση του σήματος χαμηλής συχνότητας διαμορφώνει το πλάτος τους υψηλής συχνότητας, παίζει σημαντικό ρόλο στην επεξεργασία πληροφορίας, καθώς και στις γνωστικές λειτουργίες των νευρώνων. Επίσης, αλλαγές στα μοτίβα του CFC έχουν συνδεθεί σε συγκεκριμένες νευρολογικές ψυχικές διαταραχές, όπως η νόσος Parkinson, σχιζοφρένεια και διαταραχή κοινωνικού άγχους. Έτσι, το CFC είναι απαραίτητο την κατανόηση των μοτίβων του εγκεφάλου, ενώ μπορεί να χρησιμεύσει στη διάγνωση, καθώς και στη θεραπεία διαφόρων εγκεφαλικών διαταραχών.

Στην παρούσα διατριβή ο υπολογισμός της σύζευξης συχνοτήτων ως εξής: αν  $x(j, t)$  και  $x(k, t)$  είναι δύο σήματα EEG διαφορετικών συχνοτήτων στον  $j$ -ιστό αισθητήρα και  $k$ -ιστό αισθητήρα σε μια χρονική στιγμή  $t$ , τότε το CFC προσεγγίζεται από τη διαμόρφωση του πλάτους του σήματος υψηλής συχνότητας με τη φάση του σήματος της χαμηλής συχνότητας για κάθε συνδυασμό αισθητήρων. Αρχικά, γίνεται φιλράρισμα του σήματος με ένα ζωνοπερατό (bandpass) φίλτρο και εξάγονται οι τιμές που αντιστοιχούν στην χαμηλή και υψηλή συχνότητα. Έπειτα εξάγονται η φάση και το πλάτος των σημάτων του χαμηλού και υψηλού εύρους συχνοτήτων αντίστοιχα. Προκειμένου να γίνει αυτό υπολογίζεται η μιγαδική αναπαράσταση κάθε σήματος με τη χρήση του μετασχηματισμού Hilbert (HT{ }).

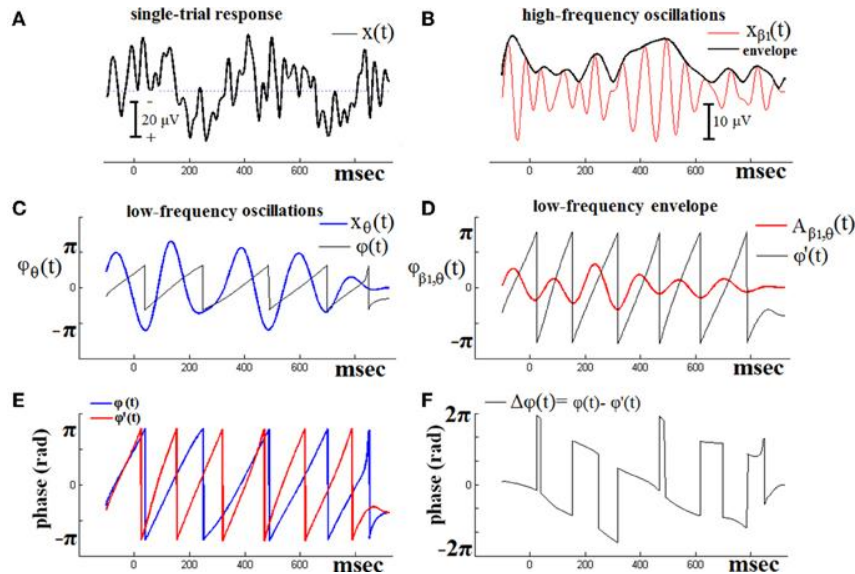
$$Z_{LF}(t) = HT\{X_{LF}\} = |Z_{LF}(t)|e^{i\varphi(t)} = |A_{LF}|e^{i\varphi_{LF}(t)} \quad (2.2)$$

$$Z_{HF}(t) = HT\{X_{HF}\} = |Z_{HF}(t)|e^{i\varphi(t)} = |A_{HF}|e^{i\varphi_{HF}(t)} \quad (2.3)$$

όπου HF δηλώνει την υψηλή συχνότητα και LF δηλώνει την χαμηλή. Έπειτα, το  $A_{HF}$  φιλτράρεται από ένα ζωνοπερατό φίλτρο στη ζώνη της χαμηλής συχνότητας και το εξαγόμενο σήμα περνάει και πάλι από μετασχηματισμό Hilbert, προκειμένου να βρεθεί η φάση του. Αν αυτή η φάση είναι ίση με  $\varphi_{LF \rightarrow HF}(t)$ , τότε υπολογίζεται το φανταστικό κομμάτι του PLV, μεταξύ του  $\varphi_{LF}$  και του  $\varphi_{LF \rightarrow HF}$ . Το IPLV ορίζεται ως :

$$IPLV_{j,k} = |Im(PLV_{j,k})| \quad (2.4)$$

όπου N είναι το πλήθος των χρονικών στιγμών, δηλαδή το μήκος των  $\varphi_{LF}$  και  $\varphi_{LF \rightarrow HF}$ . Το φανταστικό κομμάτι του PLV θεωρείται λιγότερο ευαίσθητο σε αποσβέσεις του σήματος που δημιουργούνται εξαιτίας της αγωγιμότητας [6]. Παρόλο αυτά, οι τιμές του μεταβάλλονται πολύ εύκολα όταν αλλάζει η φάση στα δύο σήματα. Στην παρούσα διπλωματική χρησιμοποιήθηκε το IPLV, προκειμένου να καθοριστεί η λειτουργική συνδεσιμότητα μεταξύ των ηλεκτροδίων του EEG.



**Εικόνα 2.2: Ανάλυση του CFC φάσης-πλάτους [5]**

### 2.2.2 Ενδοσύζευξη συχνοτήτων

Στην ενδοσύζευξη συχνοτήτων (intra frequency coupling), το σήμα φιλτράρεται και πάλι από ένα ζωνοπερατό φίλτρο σε δύο επιθυμητές συχνότητες, ενώ υπολογίζεται η φάση του με χρήση του μετασχηματισμού Hilbert. Η διαφορά αυτής της μεθόδου με το κλασικό CFC είναι ότι υπολογίζεται άμεσα το IPLV μεταξύ των σημάτων EEG σε δύο διαφορετικούς αισθητήρες, χωρίς να βρεθεί η υψηλή και η χαμηλή συχνότητα του σήματος. Για παράδειγμα, σε κάθε έναν αισθητήρα  $j$  και  $k$ , αφού βρεθούν οι γωνίες  $\varphi(j, t)$  και  $\varphi(k, t)$ , οι οποίες αντιστοιχούν στα σήματα  $x(j, t)$  και  $x(k, t)$ , το IPLV θα υπολογιστεί ως :



$$PLV_{j,k} = \frac{|\sum_{t=1}^N e^{j[\varphi_1(j,t) - \varphi_2(k,t)]}|}{N} \quad (2.5)$$

$$IPLV_{j,k} = |Im(PLV_{j,k})| \quad (2.6)$$

### 2.3 Καθολική και τοπική απόδοση

Η καθολική απόδοση (global efficiency) ενός δικτύου (γράφου) δείχνει το πόσο εύκολη μπορεί να είναι η μετάβαση από έναν κόμβο σε έναν άλλον. Σε δίκτυα εγκεφάλου, περιγράφει την ικανότητα του δικτύου να στέλνει πληροφορίες από έναν κόμβο σε έναν άλλον. Για έναν γράφο  $G$ , η καθολική απόδοση υπολογίζεται ως:

$$E_{glob}(G) = \frac{1}{N(N-1)} \sum_{i \neq j \in G} \frac{1}{d_{ij}} \quad (2.7)$$

όπου  $d_{ij}$  είναι η μικρότερη απόσταση μεταξύ του κόμβου  $i$  και  $j$  και  $N$  είναι το πλήθος των κόμβων.

Η τοπική απόδοση (local efficiency) ενός γράφου δείχνει την «αντίσταση» που μπορεί να έχει ο γράφος σε περιπτώσεις αποτυχίας μικρής κλίμακας. Ουσιαστικά, η τοπική απόδοση ενός κόμβου  $i$  χαρακτηρίζει το πόσο καλά μπορεί να μεταδοθεί πληροφορία από τους γείτονες του  $i$ , όταν ο  $i$  έχει αφαιρεθεί από τον γράφο. Η τοπική απόδοση υπολογίζεται ως :

$$E_{loc}(G) = \frac{1}{N} \sum_{i \neq j} E_{glob}(G_i) \quad (2.8)$$

όπου  $G_i$  είναι το υπογράφημα του  $G$ , το οποίο περιλαμβάνει τους γείτονες του  $i$ , χωρίς όμως τον  $i$ .

### 2.4 Διάφορες άλλες μετρικές γράφων

Πέρα από τις μετρικές που αναφέρθηκαν πιο πριν, σε έναν γράφο μπορούν να εξαχθούν και άλλα χαρακτηριστικά, όπως η σταθερά ομαδοποίησης (clustering coefficient), η οποία δείχνει τη πιθανότητα οι γείτονες ενός κόμβου στον γράφο να είναι και αυτοί συνδεδεμένοι μεταξύ τους, καθώς και το μέσο μήκος μονοπατιού (average path length), δηλαδή το μέσο πλήθος ακμών του μικρότερου μονοπατιού μεταξύ ζευγών κόμβων. Η σταθερά ομαδοποίησης  $C_i$  ενός κόμβου  $i$  αναπαριστά τη πιθανότητα οι υπόλοιποι κόμβοι  $j$  που είναι συνδεδεμένοι στον  $i$  να είναι και αυτοί συνδεδεμένοι μεταξύ τους. Η σταθερά ομαδοποίησης μπορεί να οριστεί ως [7] :

$$C_i = \frac{\sum_{k \neq i} \sum_{l \neq i} \sum_{l \neq k} w_{ik} w_{il} w_{kl}}{\sum_{k \neq i} \sum_{l \neq i} w_{ik} w_{il}} \quad (2.9)$$

Ενώ η μέση τιμή της σταθεράς ομαδοποίησης σε όλο το δίκτυο είναι:

$$C_w = \frac{\sum_{i=1}^N C_i}{N} \quad (2.10)$$

Σύμφωνα με το [7], το μήκος μιας ακμής ορίζεται ως το αντίστροφο του βάρους της ακμής, π.χ.  $L_{ij} = \frac{1}{w_{i,j}}$ , αν  $w_{i,j} \neq 0$  και  $L_{ij} = \infty$ , αν  $w_{i,j} = 0$ . Έτσι, το μέσο μήκος βεβαρημένου μονοπατιού είναι ίσο με :

$$L_w = \frac{1}{N(N-1) \sum_{i=1}^N \sum_{j \neq i}^N L_{ij}} \quad (2.11)$$

## Κεφάλαιο 3: Συνοπτικές τεχνικές γράφων


Στο κεφάλαιο αυτό παρουσιάζονται οι τεχνικές που χρησιμοποιήθηκαν για την επεξεργασία των δυναμικών γράφων, καθώς και διάφοροι μέθοδοι κατοφλίωσης. Η πρώτη τεχνική που παρουσιάζεται είναι η μη αρνητική παραγοντοποίηση πίνακα (nonnegative matrix factorization, NMF), η οποία

επιτρέπει την προσέγγιση ενός μη αρνητικού πίνακα ως γινόμενο δύο μη αρνητικών πινάκων. Η δεύτερη μέθοδος είναι ο αλγόριθμος neural gas, ο οποίος χρησιμοποιείται στη κβαντοποίηση διανυσμάτων.

### 3.1 Μη αρνητική παραγοντοποίηση πίνακα

Ένα χαρακτηριστικό διάφορων προβλημάτων της πληροφορικής είναι η ανάγκη για επεξεργασία μεγάλου όγκου δεδομένων. Κάποια από αυτά τα δεδομένα παρουσιάζονται ως μη αρνητικοί πίνακες ή τένσορες, οι οποίοι εμφανίζονται σε αρκετά πεδία εφαρμογών. Συνήθως αυτοί οι πίνακες είναι αρκετά μεγάλοι, με αποτέλεσμα η επεξεργασία τους να είναι αρκετά χρονοβόρα.

Η μέθοδος της μη αρνητικής παραγοντοποίησης πίνακα είναι μία τεχνική, η οποία μπορεί να προσεγγίσει έναν μη αρνητικό πίνακα ως ένα γινόμενο δύο μη αρνητικών πινάκων. Αν  $Y$  είναι ένας πίνακα μεγέθους  $I \times T$  τότε θα πρέπει να βρεθούν δύο πίνακες  $A$  (με μέγεθος  $I \times J$ ) και  $X$  (με μέγεθος  $J \times T$ ), έτσι ώστε το γινόμενο τους  $AX$  να προσεγγίζει τον  $Y$ . Η παρακάτω εικόνα δείχνει το πρόβλημα του NMF για  $I = 7$ ,  $T = 9$  και  $J = 3$ .



**Εικόνα 3.1: Το πρόβλημα του NNMF**

Συνήθως, σε πρακτικές εφαρμογές το επιλεγόμενο  $J$  είναι αρκετά μικρότερο από τα  $I$  και  $T$ . Επίσης, πρέπει να σημειωθεί ότι ο πίνακας  $AX$  είναι μία προσέγγιση του γινομένου  $Y$ , αφού δεν είναι δυνατόν να βρεθούν πίνακες  $A$  και  $X$ , τέτοιοι ώστε  $Y = AX$ . Συνήθως ο πίνακας  $Y$  εκφράζεται ως :

$$Y = AX + E \quad (3.1)$$

όπου  $E$  είναι ένας πίνακας  $I \times T$ , ο οποίος δείχνει το σφάλμα προσέγγισης. Έτσι, ο πίνακας  $AX$  μπορεί να θεωρηθεί ως μία συμπιεσμένη αναπαράσταση του  $Y$ , με τάξη μικρότερη ή ίση από  $J$ .

#### 3.1.1 Αλγόριθμοι επίλυσης του προβλήματος του NNMF

Οι πιο δημοφιλείς αλγόριθμοι που επιλύουν το πρόβλημα του NNMF είναι οι πολλαπλασιαστικοί κανόνες [8][9] (αλγόριθμος 3.1). Προκειμένου να οριστούν αυτοί οι κανόνες, επιλέγεται ο ένας από τους δύο παράγοντες (είτε ο  $A$ , είτε ο  $X$ ) και ελαχιστοποιείται η συνάρτηση κόστους ως προς τον άλλον παράγοντα. Μια τέτοια συνάρτηση κόστους μπορεί να κατασκευασθεί χρησιμοποιώντας ένα μέτρο απόστασης μεταξύ δύο πινάκων  $B$  και  $D$ :

$$\|B - D\|^2 = \sum_{ij} (B_{ij} - D_{ij})^2 \quad (3.2)$$

Η συνάρτηση κόστους μπορεί να γραφθεί ως :

$$f = \|Y - AX\|^2 \quad (3.3)$$

με:

$$A \geq 0 \text{ και } X \geq 0$$

Χρησιμοποιώντας τη μέθοδο της κατάβασης δυναμικού [11] (gradient descend), οι πίνακες  $A$  και  $X$  μπορούν ανανεωθούν ως :

$$A \leftarrow A \frac{[YX]}{[AX^T X]} \tag{3.4}$$

$$X \leftarrow X \frac{[Y^T A]}{[XA^T A]} \tag{3.5}$$

Αλγόριθμος 3.1 - Πολλαπλασιαστικοί πίνακες	
1.	Αρχικοποίηση των πινάκων $A^U$ και $X^U$ και $k = 0$
2.	Επανάλαβε
3.	$A^{k+1} = A^k \frac{[YX^k]}{[A^k(X^k)^T X^k]}$
4.	$X^{k+1} = X^k \frac{[Y^T A^{k+1}]}{[X^k(A^{k+1})^T A^{k+1}]}$
5.	Ωσπου να επαληθευθεί η συνθήκη τερματισμού

Ένας διαφορετικός τρόπος επίλυσης του προβλήματος του NMF είναι η χρήση της εναλλακτικής μεθόδου ελαχίστων τετραγώνων, η οποία ήταν και η πρώτη τεχνική που προτάθηκε για της επίλυση αυτού του προβλήματος. Είναι γνωστό, ότι κρατώντας σταθερό τον πίνακα  $A$  ή  $X$ , το πρόβλημα του NMF μετατρέπεται σε πρόβλημα ελαχίστων τετραγώνων με μη αρνητικό περιορισμό.

Αλγόριθμος 3.2 - Εναλλακτική μέθοδος ελαχίστων τετραγώνων	
1.	Αρχικοποίηση των πινάκων $A$ και $X$
2.	Επανάλαβε
3.	Λύσε: $\min_{V > 0} \frac{1}{2} \ A - UV^T\ $
4.	Λύσε: $\min_{U > 0} \frac{1}{2} \ A - VU^T\ $
5.	Ωσπου να επαληθευθεί η συνθήκη τερματισμού

Μία τρίτη μέθοδος είναι η χρήση της μη αρνητικής παραγοντοποίησης πίνακα, η οποία μπορεί να θεωρηθεί ως μία μη γραμμική βελτιστοποίηση προβλήματος σε ένα κυρτό σύνολο. Είναι γνωστό ότι η προβολή σε ένα τέτοιο σύνολο είναι πολύ απλή να υπολογιστεί, ενώ κάθε αρνητική τιμή της θεωρείται ότι είναι μηδενική. Σε αυτή τη περίπτωση η κατάβαση χαρακτηρίζεται από τα ακόλουθα βήματα :

- Υπολογισμός της κλίσης  $\nabla F(x^k)$
- Επιλογή του μεγέθους βήματος  $a^k$
- Ανανέωση της μεταβλητής:  $x^{k+1} = [x^k - a^k \nabla F(x^k)]$

### 3.2 Κβαντοποίηση διανυσμάτων – Neural gas

Η κβαντοποίηση διανυσμάτων είναι μία κλασική τεχνική, η οποία έχει τη δυνατότητα να προσεγγίσει μία συνεχή συνάρτηση πυκνότητας πιθανότητα  $p(x)$ , με  $x \in \mathbb{R}^n$ , χρησιμοποιώντας έναν πεπερασμένο αριθμό από χαρακτηριστικά (prototypes)  $\{c_1, \dots, c_k\} \in \mathbb{R}^n$ . Αυτό το σύνολο χαρακτηριστικών αναφέρεται ως βιβλίο κωδίκων (codebook) [12]. Ο σχεδιασμός τους μπορεί να γίνει χρησιμοποιώντας αλγόριθμους ομαδοποίησης. Όταν έχει καθοριστεί ποιο θα είναι το βιβλίο κωδίκων, η προσέγγιση του  $x$  γίνεται αφού βρεθεί το διάνυσμα  $c$  που είναι όσο το δυνατόν πιο κοντά στο  $x$ , έτσι ώστε :

$$\|x - c\| = \min_i \|x - c_i\| \tag{3.6}$$

Το βιβλίο κωδίκων μπορεί να σχεδιαστεί, έτσι ώστε να ελαχιστοποιείται το τετραγωνικό σφάλμα της κβαντοποίησης :

$$E = \int \|x - c\|^2 p(x) dx \tag{3.7}$$

Μία επαναληπτική προσέγγιση για την εύρεση του βιβλίου κωδίκων μπορεί να εξαχθεί από την επόμενη εξίσωση :

$$c_i(t+1) = c_i(t) + n(t)\delta_{wi}[x(t) - c_i(t)] \quad (3.8)$$

όπου  $w$  είναι ο δείκτης του χαρακτηριστικού που είναι όσο το δυνατόν πιο κοντά στο  $x(t)$  και ορίζεται ως το "χαρακτηριστικό νικητής" (winning prototype). Επίσης,

$$\delta_{wi} = 1, \text{ για } w = i \quad (3.9)$$

$$\delta_{wi} = 0, \text{ για } w \neq i \quad (3.10)$$


ενώ  $n > 0$ , ικανοποιεί τις παρακάτω συνθήκες :

$$\sum n(t) = \infty \text{ και } \sum n(t)^2 < \infty \quad (3.11)$$

Συνήθως, το  $n(t)$  επιλέγεται να μειώνεται μονοτονικά με τη πάροδο του χρόνου, π.χ. θα μπορούσε να επιλεγεί το παρακάτω  $n$ :

$$n(t) = n_0 \left(1 - \frac{t}{T}\right) \quad (3.12)$$

όπου  $n_0 \in (0,1]$  και  $T$  είναι ο μέγιστος αριθμός επαναλήψεων. Τέλος, τα αποτελέσματα της κβαντοποίησης διανυσμάτων μπορούν να αναπαρασταθούν με την χρήση των διαγραμμάτων Voronoi. Ουσιαστικά, ο χώρος χωρίζεται σε ένα πεπερασμένο αριθμό από περιοχές, τα οποία συνορεύονται από υπερεπίπεδα. Κάθε περιοχή αναπαρίσταται από ένα διάνυσμα βιβλίου κωδικών, το οποίο είναι ο πιο κοντινός γείτονας σε κάθε σημείο στην ίδια περιοχή. Στη παρακάτω φωτογραφία φαίνεται ένα διάγραμμα Voronoi.



**Εικόνα 3.2: Διάγραμμα Voronoi σε δύο διαστάσεις. Τα διανύσματα βιβλίων κωδικών αναπαριστώνται με μαύρες κουκκίδες [12]**

Ο αλγόριθμος neural gas είναι μία μέθοδος, η οποία χρησιμοποιείται στην κβαντοποίηση διανυσμάτων σε ένα νευρωνικό δίκτυο. Συγκεκριμένα, ελαχιστοποιεί μία συνάρτηση κόστους, ενώ χρησιμοποιεί τεχνική για αποφυγή τοπικών βέλτιστων. Ο στόχος του neural gas είναι να βρει πρωτότυπα  $c_i \in \mathbb{R}^n$  με  $i = 1, \dots, K$ , τα οποία αναπαριστούν μία κατανομή  $P$ . Αυτό γίνεται ελαχιστοποιώντας τη συνάρτηση κόστους :

$$E_{NG}(c_i) = \frac{\sum_{i=1}^K \int h(r_i(x, c_i)) d(x, c_i) P(dx)}{2C(\lambda)} \quad (3.13)$$

όπου  $d(\cdot, \cdot)$  δηλώνει την ευκλείδεια απόσταση και  $r_i$  είναι η τάξη των prototypes, τα οποία είναι ταξινομημένα ως προς τις αποστάσεις  $d$ . Επίσης,  $h(t) = e^{-\lambda t}$  με  $\lambda > 0$  και  $C(\lambda) = \sum_{i=1}^K h(r_i)$ . Μία βέλτιστη τοπολογική ταξινόμηση πετυχαίνεται χρησιμοποιώντας ταξινόμηση γειτόνων (neighbor ranking) στα σήματα εισόδου σε κάθε βήμα εκπαίδευσης. Προκειμένου να γίνει η ταξινόμηση γειτόνων, ο κάθε νευρώνας συγκρίνει την απόσταση του από το διάνυσμα εισόδου με τις αποστάσεις των υπόλοιπων νευρώνων από το σήμα εισόδου. Η ταξινόμηση γειτόνων παρέχει μια στρατηγική με μηχανισμούς που σχετίζονται με έγκυρα στατιστικά στοιχεία. Σε κάθε βήμα  $t$ , οι ευκλείδειες αποστάσεις μεταξύ ενός διανύσματος εισόδου  $x_t$  και όλων των πρωτοτύπων διανυσμάτων  $c_k(t)$  με  $k = 1, \dots, K$  υπολογίζονται ως :

$$d_k(x_t) = \|x_t - c_k(t)\| \quad (3.14)$$

και

$$d(t) = (d_1(x_t), \dots, d_K(x_t))^T \quad (3.15)$$

Τα prototypes υπολογίζονται όπως φαίνεται παρακάτω:

$$c_k(t+1) = c_k(t) + nh(r_k(t))(x_t - c_k(t)) \quad (3.16)$$

όπου  $h(r) = e^{-\frac{r}{\rho(t)}}$  και  $\rho(t)$  είναι το πλάτος του γειτονικού νευρώνα. Κατά τη διάρκεια των επαναλήψεων, οι τιμές των  $\rho(t)$  και  $n(t)$  μειώνονται εκθετικά από τις αρχικές τιμές τους.

$$n(t) = n_0 \left(\frac{n_f}{n_0}\right)^{\frac{t}{T_f}}, \rho(t) = \rho_0 \left(\frac{\rho_f}{\rho_0}\right)^{\frac{t}{T_f}} \quad (3.17)$$

με  $n_0$  και  $\rho_0$  να είναι οι αρχικές παράμετροι αποσύνθεσης, ενώ οι  $n_f$  και  $\rho_f$  είναι οι τελικές παράμετροι αποσύνθεσης. Τα prototypes  $c_k$  αρχικοποιούνται τυχαία από τα διανύσματα του συνόλου εκπαίδευσης. Παρακάτω παρουσιάζεται ο αλγόριθμος του neural gas.

Αλγόριθμος 3.3	
1.	Αρχικοποίηση του $K$ , $c_k$ , $k = 1, \dots, K$ , $\rho_0$ , $n_0$ , $\rho_f$ , $n_f$ και $T_f$
2.	Όρισε $t = 1$
3.	Επανελάβε
4.	Υπολογισμός των αποστάσεων $d_k(x_t)$ , για $k = 1, \dots, K$
5.	Ταξινόμηση των στοιχείων του $d_t$ και ανάθεση σε κάθε prototype $c_k$ μίας τάξης $r_k(t)$ , η οποία παίρνει τιμές από 0 ως $K - 1$
6.	Υπολογισμός των $n(t)$ και $\rho(t)$
7.	Ανανέωση των τιμών του $c_k$ για $k = 1, \dots, K$
8.	Όρισε $t = t + 1$
9.	Ωσπου να επαληθευθεί η συνθήκη τερματισμού

Ο αλγόριθμος neural gas δεν είναι «ευαίσθητος» στην αρχικοποίηση των νευρώνων, ενώ μπορεί να πετύχει μικρό σφάλμα κβαντοποίησης. Επίσης, το σφάλμα κβαντοποίησης του είναι μικρότερο σε σχέση με άλλες παρόμοιες μεθόδους. Παρόλο αυτά, ανάλογα με τη δομή των δεδομένων, ο neural gas μπορεί να μην πετύχει το βέλτιστο ασυμπτωτικό σφάλμα. Όσον αφορά τον χρόνο εκτέλεσης, η σειριακή υλοποίηση του neural gas έχει χρονική πολυπλοκότητα  $O(K \log K)$ , ενώ η παράλληλη  $O(K)$ .

### 3.3 Χρήση κατωφλίου στους δυναμικούς γραφούς


Πολλές φορές οι «αδύναμες» ή μη σημαντικές συνδέσεις μεταξύ των κόμβων ενός δυναμικού γράφου θεωρούνται ότι τείνουν να επικαλύπτουν τις πιο σημαντικές συνδέσεις [10]. Οι «αδύναμες» συνδέσεις μπορεί να είναι ψευδείς ή ακόμα και θόρυβος, με αποτέλεσμα η παρουσία τους να οδηγήσει σε λανθασμένα αποτελέσματα. Για αυτόν τον λόγο, χρησιμοποιούνται συχνά τεχνικές κατωφλίου, οι οποίες βοηθούν στην εξάλειψη των αδύναμων συνδέσεων.

Οι τεχνικές κατωφλίου σε ένα γράφο αποτελούνται από τρεις κατηγορίες: σταθερού κατωφλίου (fixed threshold), σταθερού μέσου βαθμού (fixed average degree) και σταθερής πυκνότητας ακμής (fixed edge density). Η πρώτη μέθοδος χρησιμοποιεί ένα μόνο κατώφλι, το οποίο προκύπτει από ένα από τα παρακάτω κριτήρια:

- Χρήση του 5% του επιπέδου σημαντικότητας
- Τυχαία τιμή
- Επιλογή της μέγιστης τιμής κατωφλίου, έτσι ώστε στον γράφο που θα προκύψει, να υπάρχει διαδρομή από έναν κόμβο του γράφου προς όλους τους άλλους κόμβους του.

Παρόλο αυτά, η συνδεσιμότητα διαφέρει ανάλογα με τις συνθήκες και από άτομο σε άτομο, με αποτέλεσμα να προκύπτουν διαφορετικοί μέσοι βαθμοί γράφου για κάθε ένα υποκείμενο ή κατάσταση.

Όσον αφορά τη μέθοδο σταθερού βαθμού, αυτή εξασφαλίζει ότι όλοι οι κόμβοι του γράφου (π.χ. για κάθε υποκείμενο ή κατάσταση) θα έχουν τον ίδιο βαθμό. Το μεγάλο μειονέκτημα αυτής της τεχνικής είναι ότι η χρήση της σε γράφους με μεγάλο μέσο βαθμό και γενικά μικρής συνδεσιμότητας, μπορεί να οδηγήσει στη διατήρηση «αδύναμων» ακμών. Αντίστροφα, αν η ίδια τεχνική εφαρμοστεί σε γράφους με μικρό μέσο βαθμό και μεγάλη συνδεσιμότητα, μπορεί σε αυτή τη περίπτωση να αποκοπούν «δυνατές» συνδέσεις. Η εφαρμογή της μεθόδου σταθερού βαθμού φαίνεται στην εικόνα 3.3 [13].



**Εικόνα 3.3: Εφαρμογή της μεθόδου σταθερού βαθμού σε γράφους με μεγάλο και μικρό μέσο βαθμό αντίστοιχα. Οι «δυνατές» συνδέσεις εμφανίζονται με μαύρο χρώμα [13]**

## Κεφάλαιο 4: Ταξινομητές

Σε αυτό το κεφάλαιο γίνεται μια εισαγωγή στην ταξινόμηση και τη μηχανική μάθηση, ενώ επίσης περιγράφονται οι μηχανές διανυσμάτων υποστήριξης (Support Vector Machines, SVM) καθώς και τα νευρωνικά δίκτυα (neural networks). Τέλος, παρουσιάζεται ο αλγόριθμος του extreme learning machine (ELM), ο οποίος εφαρμόστηκε στη πρόβλεψη της ηλικίας των υποκειμένων.

### 4.1 Εισαγωγή στην αναγνώριση προτύπων

Προκειμένου να επιτευχθεί η αναγνώριση κάποιου προτύπου, χρειάζεται να γίνει η προσέγγιση μιας συνάρτησης  $f: R^N \rightarrow \{\pm 1\}$ , χρησιμοποιώντας δεδομένα εκπαίδευσης εισόδου - εξόδου,  $(x_1, y_1), (x_2, y_2), \dots, (x_r, y_r) \in R^N$ , έτσι ώστε η  $f$  να μπορεί να ταξινομήσει άγνωστα δεδομένα  $(x, y)$ , δηλαδή να ισχύει  $f(x) = y$ . Παρόλο αυτά, μπορεί η συνάρτηση  $f$  να ικανοποιεί τη σχέση  $f(x_i) = y_i$  για κάθε  $i$  από 1 ως  $r$ , αλλά να αδυνατεί να ταξινομήσει άγνωστα δεδομένα. Για παράδειγμα, αν  $(\bar{x}_1, \bar{y}_1), (\bar{x}_2, \bar{y}_2), \dots, (\bar{x}_{\bar{r}}, \bar{y}_{\bar{r}})$  είναι τα δείγματα που ανήκουν στο σύνολο των δεδομένων ελέγχου, μπορεί να υπάρχει άλλη μια συνάρτηση  $f^*$  τέτοια ώστε  $f^*(x_i) = f(x_i)$ , για κάθε  $i$  από 1 ως  $r$ , αλλά να ισχύει ότι  $f^*(\bar{x}_j) \neq f(\bar{x}_j)$ , για κάθε  $j$  από 1 ως  $\bar{r}$ . Έτσι, ο μόνος τρόπος που καθορίζει ποια από τις δύο συναρτήσεις θα επιλεγεί, είναι η ελαχιστοποίηση του σφάλματος εκπαίδευσης (εμπειρικό ρίσκο, empirical risk):

$$R_{emp}[f] = \frac{1}{r} \sum_{i=1}^r |f(x_i) - y_i| \quad (4.1)$$

Η στατιστική θεωρία μάθησης ή αλλιώς θεωρία VC (Vapnik-Chervonenkis) δείχνει ότι είναι αναγκαίος ο περιορισμός των κλάσεων των συναρτήσεων από τις οποίες επιλέγεται η συνάρτηση  $f$ , η οποία έχει χωρητικότητα που είναι κατάλληλη για το πλήθος των δεδομένων εκπαίδευσης. Σύμφωνα με τη θεωρία VC, η χωρητικότητα ορίζεται ως ο μεγαλύτερος αριθμός σημείων, τα οποία μπορούν να διαχωριστούν με κάθε πιθανό τρόπο.

## 4.2 Υπερεπίπεδοι ταξινόμητές


Για να σχεδιαστούν οι αλγόριθμοι μηχανικής μάθησης θα πρέπει να καθοριστεί το πλήθος των συναρτήσεων, των οποίων η χωρητικότητα μπορεί να υπολογιστεί. Προκειμένου να γίνει αυτό, επινοήθηκε η κλάση των υπερεπίπεδων (hyperplane):

$$(w \cdot x) + b = 0 \quad (4.2)$$

όπου  $w \in R^n$  και  $b \in R$  και οι οποίες αντιστοιχούν στις συναρτήσεις απόφασης:

$$f(x) = \text{sgn}((w \cdot x) + b) \quad (4.3)$$

Ουσιαστικά, το υπερεπίπεδο είναι μία γραμμική συνάρτηση, η οποία μπορεί να διαχωρίζει τα δεδομένα μεταξύ τους. Η εικόνα 4.1 απεικονίζει ένα πρόβλημα δύο διαστάσεων, όπου σε αυτή τη περίπτωση το υπερεπίπεδο είναι μια ευθεία. Ως διάκενο (margin) ορίζεται το διπλάσιο της απόστασης μεταξύ της ευθείας και του σημείου που είναι πιο κοντά. Έτσι, ένα υπερεπίπεδο θεωρείται βέλτιστο όταν μεγιστοποιείται η τιμή που έχει το διάκενο. Στην εικόνα 4.1 φαίνεται ένα παράδειγμα, όπου το υπερεπίπεδο δίνει το μέγιστο διάκενο.



**Εικόνα 4.1: Το βέλτιστο διαχωριζόμενο υπερεπίπεδο μεταξύ των δεδομένων [14]**

Για να κατασκευαστεί μία βέλτιστη υπερεπίπεδη συνάρτηση (optimal hyperplane function), θα πρέπει λυθεί το παρακάτω πρόβλημα βελτιστοποίησης:

$$\text{Ελαχιστοποίηση: } r(w) = \frac{1}{2} \|w\|^2 \quad (4.4)$$

$$\text{με περιορισμό } y_i \cdot ((w \cdot x_i) + b) \geq 1, i = 1, \dots, r$$

Αυτό το πρόβλημα περιορισμού επιλύεται με τη χρήση των πολλαπλασιαστών Lagrange:

$$L(w, b, a) = \frac{1}{2} \|w\|^2 - \sum_{i=1}^r a_i (y_i ((w \cdot x_i) + b) - 1) \quad (4.5)$$

Χρησιμοποιώντας τις συνθήκες Karush-Khun-Tucker [15], προκύπτει ότι:

$$\sum_{i=1}^r a_i y_i = 0 \quad (4.6)$$

και


$$w = \sum_{i=1}^r a_i y_i x_i \quad (4.7)$$

Τα διανύσματα των λύσεων, για τα οποία ισχύει  $a_i \neq 0$ , ονομάζονται διανύσματα υποστήριξης (support vectors), ενώ η μεταβλητή  $w$  είναι το διάνυσμα βάρους.

### 4.2.1 Χώρος καταστάσεων και πυρήνες

Η κατασκευή μιας μηχανής διανύσματος υποστήριξης προϋποθέτει πολλές φορές την αντιστοίχιση των χαρακτηριστικών σε κάποιο άλλο πεδίο ορισμού (χώρος των χαρακτηριστικών, feature space). Ο λόγος που γίνεται αυτό είναι ότι συνήθως παρουσιάζονται προβλήματα, στα οποία δεν μπορεί να γίνει γραμμικός διαχωρισμός των κλάσεων. Ένα τέτοιο παράδειγμα φαίνεται στην εικόνα 4.2. Εισάγοντας μια δεύτερη μεταβλητή  $z = \sqrt{x^2 + y^2}$ , το πρόβλημα της εικόνα 4.2 μπορεί να μετασχηματισθεί σε αυτό της εικόνας 4.3, το οποίο είναι γραμμικώς διαχωρίσιμο. Πολλές φορές όμως, σε προβλήματα με μεγάλο πλήθος δεδομένων, ο μετασχηματισμός του κάθε ενός σημείου στον χώρο των χαρακτηριστικών καθίσταται αρκετά χρονοβόρος (ειδικά αν αυξάνεται η διάσταση του χώρου των χαρακτηριστικών). Αν γίνει αντικατάσταση των  $x$  και  $y$  στις εξισώσεις (4.3), (4.6) και (4.7) με  $\Phi(x)$  και  $\Phi(y)$  αντίστοιχα, όπου  $\Phi$  να είναι μία μη γραμμική διανυσματική συνάρτηση, παρατηρείται ότι εμφανίζονται εσωτερικά γινόμενα της μορφής:

$$k(x, y) = \Phi(x) \cdot \Phi(y) \tag{4.8}$$




**Εικόνα 4.2: Μη γραμμικό διαχωρίσιμο πρόβλημα [16]**

Έτσι, κάθε εσωτερικό γινόμενο μπορεί να αντικατασταθεί από τη  $k(x, y)$ . Η συνάρτηση  $k(x, y)$  ονομάζεται συνάρτηση πυρήνας (kernel) και ο λόγος που χρησιμοποιείται είναι για να μειωθούν οι πράξεις, ειδικά όταν η διάσταση του διανύσματος  $x$  είναι μικρότερη από τη διάσταση του διανύσματος  $\Phi(x)$ . Επίσης, με τη χρήση των συναρτήσεων πυρήνα, δεν χρειάζεται να είναι γνωστή η διάσταση του χώρου των χαρακτηριστικών. Οι πιο γνωστοί πυρήνες είναι οι:

Γκαουσιανή RBF	$e^{-\frac{\ x-y\ ^2}{2\sigma^2}}$
Πολυωνυμική	$x^T \cdot y + \theta$
Σιγμοειδής	$\tanh(a \cdot x^T \cdot y + \theta)$
Αντίστροφη πολυτετραγωνική	$\frac{1}{\sqrt{\ x - y\ ^2 + c^2}}$

**Πίνακας 4.1: Πύρηνες σε υπερεπίπεδους ταξινομητές**





**Εικόνα 4.3: Το πρόβλημα της εικόνας 4.2 μετά τη χρήση του μετασχηματισμού [16]**

### 4.2.2 Μηχανές διανυσμάτων υποστήριξης

Για να κατασκευαστεί μία μηχανή διανύσματος υποστήριξης θα πρέπει αρχικά να υπολογιστεί ένα βέλτιστο υπερεπίπεδο στον χώρο των χαρακτηριστικών. Ως τώρα γίνεται αντικατάσταση των δειγμάτων εκπαίδευσης  $x$  με  $\Phi(x)$ . Αυτό σημαίνει ότι το διάνυσμα βάρους  $w$  θα βρίσκεται στον χώρο των χαρακτηριστικών και δεν θα έχει καμία αντιστοιχία με τον χώρο εισόδου. Επίσης, όπως αναφέρθηκε πιο πριν, εμφανίζονται πάντα εσωτερικά γινόμενα σε συνάρτηση με την  $\Phi(x)$ , με αποτέλεσμα η εξίσωση (4.3) να μετασχηματίζεται ως:

$$f(x) = \text{sgn}(\sum_{i=1}^r y_i a_i \cdot k(x, x_i) + b) \quad (4.9)$$

Παρόλο αυτά, υπάρχουν προβλήματα, στα οποία δεν μπορεί να βρεθεί κάποιο διαχωριζόμενο υπερεπίπεδο, π.χ. αν υπάρχει υψηλό επίπεδο θορύβου στα δεδομένα εισόδου. Σε αυτές τις περιπτώσεις εισάγονται μεταβλητές χαλάρωσης (slack variables):

$$\xi_i \geq 0, \text{ με } i = 1, \dots, r \quad (4.10)$$

οι οποίες αλλάζουν την μορφή των περιορισμών καθώς και της αντικειμενικής συνάρτησης στην εξίσωση (4.4). Έτσι, προκύπτει το παρακάτω πρόβλημα:

$$\text{Ελαχιστοποίηση: } r(w) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^r \xi_i \quad (4.11)$$

$$\text{με περιορισμό } y_i \cdot ((w \cdot x) + b) \geq 1 - \xi_i, i = 1, \dots, r$$

όπου  $C$  είναι μια σταθερά (tradeoff parameter).


## 4.3 Τεχνητά νευρωνικά δίκτυα

Ένας αποδοτικός τρόπος για την επίλυση πολύπλοκων προβλημάτων είναι η χρήση της τεχνητής «δίαυρε και βασίλευε». Ένα πολύπλοκο σύστημα μπορεί να διασπαστεί σε μικρότερα στοιχεία, προκειμένου να γίνει πιο εύκολη η κατανόηση του. Η χρήση των δικτύων είναι ένας τρόπος για να επιτευχθεί αυτό. Τα δίκτυα αποτελούνται από κόμβους, καθώς και συνδέσεις μεταξύ των κόμβων. Οι κόμβοι μπορούν να θεωρηθούν ως υπολογιστικές μονάδες, οι οποίες λαμβάνουν δεδομένα εισόδου και τα επεξεργάζονται, προκειμένου να υπολογίσουν μια έξοδο. Οι συνδέσεις μεταξύ των κόμβων καθορίζουν τη ροή της πληροφορίας. Αυτές μπορεί να είναι μη κατευθυνόμενες ή κατευθυνόμενες, όταν η πληροφορία ρέει προς μία κατεύθυνση ή προς και τις δύο αντίστοιχα.


Ένα είδος δικτύου είναι τα τεχνητά νευρωνικά δίκτυα. Ένα τεχνητό νευρωνικό δίκτυο είναι ένα υπολογιστικό μοντέλο, το οποίο εμπνεύστηκε από τους φυσικούς νευρώνες. Όπως περιγράφηκε στο κεφάλαιο 1, οι φυσικοί νευρώνες του εγκεφάλου λαμβάνουν σήματα μέσω των συνάψεων που βρίσκονται στους δενδρίτες ή στη μεμβράνη του νευρώνα. Όταν τα λαμβανόμενα σήματα είναι αρκετά

ισχυρά (δηλαδή αν ξεπερνούν ένα συγκεκριμένο κατώφλι), ο νευρώνας ενεργοποιείται και στέλνει ένα σήμα μέσω του άξονα. Αυτό το σήμα μπορεί να σταλθεί μέσω του άξονα σε μια άλλη σύναψη και μπορεί να ενεργοποιεί κάποιον άλλον νευρώνα.

Η πολυπλοκότητα των πραγματικών νευρώνων θεωρείται αμελητέα όταν μοντελοποιείται ένα τεχνητό νευρωνικό δίκτυο [17]. Οι τεχνητοί νευρώνες αποτελούνται από εισόδους (όπως οι συνάψεις), οι οποίες πολλαπλασιάζονται από κάποια βάρη (ισχύς των αντίστοιχων σημάτων) και έπειτα από μία μαθηματική συνάρτηση η οποία καθορίζει την ενεργοποίηση του νευρώνα. Γενικά τα τεχνητά νευρωνικά δίκτυα συνδυάζουν πολλούς τεχνητούς νευρώνες ή ακόμα πολλά στρώματα νευρώνων (πολυστρωματικά νευρωνικά δίκτυα), προκειμένου να επεξεργαστούν δεδομένα. Όσο μεγαλύτερο είναι το βάρος σε έναν τεχνητό νευρώνα, τόσο πιο «δυνατή» είσοδος θα προκύψει, αφού το βάρος θα πολλαπλασιαστεί με αυτή. Τα βάρη μπορεί να είναι ακόμα και αρνητικά, με αποτέλεσμα η είσοδος να παίρνουν και αρνητικές τιμές. Επίσης, ανάλογα με τις τιμές τους, ο τρόπος υπολογισμού σε έναν νευρώνα μπορεί να είναι διαφορετικός. Έτσι, προσαρμόζοντας τις τιμές τους, μπορούν να εξαχθούν διαφορετικοί έξοδοι για συγκεκριμένο αριθμός εισόδων.



**Εικόνα 4.4: Τεχνητός νευρώνας**



**Εικόνα 4.5: Πολυστρωματικό νευρωνικό δίκτυο [18]**

Παρόλο αυτά, όταν ένα τεχνητό νευρωνικό δίκτυο περιέχει εκατοντάδες ή χιλιάδες νευρώνες, θα είναι αρκετά πολύπλοκο να βρεθούν όλα τα βάρη χειροκίνητα. Για αυτόν τον λόγο υπάρχουν αλγόριθμοι οι οποίοι μπορούν να προσαρμόσουν τα βάρη σε ένα τεχνητό νευρωνικό δίκτυο, προκειμένου να υπολογιστεί η επιθυμητή έξοδος από το δίκτυο. Η διαδικασία με την οποία προσαρμόζονται τα βάρη των νευρώνων ονομάζεται μάθηση ή εκπαίδευση.

### 4.3.1 Extreme learning machine

Ο αλγόριθμος του extreme learning machine (ELM) είναι μία νέα τεχνική που εφαρμόζεται σε νευρωνικά δίκτυα πρόσθιας τροφοδότησης μονού επιπέδου (single layer feed-forward, SLFN), προκειμένου να βελτιωθεί η απόδοση του νευρωνικού δικτύου [19]. Αυτός ο αλγόριθμος διαφέρει από τις άλλες

συμβατικές μεθόδους μηχανικής μάθησης, οι οποίοι συνήθως χρειάζονται και άλλες παραμέτρους όπως ποσοστό εκμάθησης ή πολλές φορές σταματούν σε τοπικό ελάχιστο. Ο ELM είναι αρκετά πιο γρήγορος σε σχέση με άλλες παραδοσιακές μεθόδους, ενώ η φάση εκπαίδευσης του αλγόριθμου μπορεί να πετύχει αρκετά καλή επίδοση. Επιπρόσθετα, έχει εφαρμοστεί επιτυχώς σε αρκετά προβλήματα ταξινόμησης και παλινδρόμησης (regression). Παρόλο αυτά, ένα πρόβλημα του ELM είναι ότι σε αρκετές περιπτώσεις χρειάζεται περισσότερους κρυφούς νευρώνες μέσα στο δίκτυο σε σχέση με άλλες κλασσικές τεχνικές.

Αν  $N$  είναι το πλήθος των δειγμάτων εκπαίδευσης και  $(x_i, t_i) \in R^n \times R^m$  με  $i = 1, 2, \dots, N$ , η έξοδος ενός SLFN με  $\tilde{N}$  κρυφούς κόμβους μπορεί να αναπαρασταθεί ως:

$$o_j = \sum_{i=1}^{\tilde{N}} \beta_i f_i(x_j) = \sum_{i=1}^{\tilde{N}} \beta_i f(x_j; a_i; b_i) \quad (4.12)$$

με  $j = 1, \dots, N$ . Επίσης,  $o_j$  είναι το διάνυσμα εξόδου του SLFN σε σχέση με το δείγμα εισόδου  $x_i$ . Τα  $a_i = [a_{i1}, a_{i2}, \dots, a_{im}]^T$  και  $b_i$  είναι οι παράμετροι εκπαίδευσης, οι οποίοι δημιουργούνται αυτόματα στον  $j$ -ιοστό κόμβο. Επίσης,  $\beta_i = [\beta_{i1}, \beta_{i2}, \dots, \beta_{im}]^T$  είναι η σύνδεση, η οποία συνδέει τον  $j$ -ιοστό κρυφό κόμβο και τους κόμβους εξόδου, ενώ η  $f(x; a_i; b_i)$  είναι η συνάρτηση ενεργοποίησης του ELM. Αν  $a_i, b_i$  είναι το εσωτερικό γινόμενο των  $a_i$  και  $x_j$ , η προηγούμενη εξίσωση μπορεί να γραφθεί ως :

$$H\beta = 0 \quad (4.13)$$

όπου:

$$H = \begin{bmatrix} f(\alpha_1 \cdot x_1 + b_1) & \cdots & f(\alpha_{\tilde{N}} \cdot x_1 + b_{\tilde{N}}) \\ \vdots & \ddots & \vdots \\ f(\alpha_1 \cdot x_N + b_1) & \cdots & f(\alpha_{\tilde{N}} \cdot x_N + b_{\tilde{N}}) \end{bmatrix}, \beta = \begin{bmatrix} \beta_1^T \\ \vdots \\ \beta_{\tilde{N}}^T \end{bmatrix}_{\tilde{N} \times m}, o = \begin{bmatrix} o_1^T \\ \vdots \\ o_N^T \end{bmatrix}_{N \times m} \quad (4.14)$$

Προκειμένου να ελαχιστοποιηθεί η συνάρτηση κόστους  $\|O - T\|$ , οι παράμετροι  $a_i$  και  $b_i$  μπορούν να πάρουν τυχαίες τιμές ανεξάρτητα από τις τιμές στην είσοδο. Έπειτα, η προηγούμενη εξίσωση μετατρέπεται σε ένα γραμμικό σύστημα εξισώσεων, ενώ τα βάρη εξόδου  $\hat{\beta}$  μπορούν να υπολογιστούν, όπως φαίνεται παρακάτω :

$$\hat{\beta} = H^+ T \quad (4.15)$$

όπου  $H^+$  είναι ο ψευδοαντίστροφος Moore-Penrose του  $H$  [20].

## Κεφάλαιο 5: Περιγραφή μεθόδων και τεχνικών

Σε αυτό το κεφάλαιο παρουσιάζονται οι μέθοδοι και οι τεχνικές που χρησιμοποιήθηκαν προκειμένου να γίνει η πρόβλεψη της ηλικίας των υποκειμένων, καθώς και της ομαδοποίησής τους σε δύο ηλικιακές ομάδες. Αρχικά, περιγράφεται η βάση από τα σήματα EEG που χρησιμοποιήθηκαν, καθώς και ο τρόπος εξαγωγής των δυναμικών γράφων, όπως περιγράφεται στο κεφάλαιο 2. Έπειτα, αναλύεται ο τρόπος εφαρμογής των αλγόριθμων, που αναφέρθηκαν στο κεφάλαιο 3, πάνω στους δυναμικούς γράφους. Τέλος, παρουσιάζονται τα μετρικά που χρησιμοποιήθηκαν στην πρόβλεψη της ηλικίας, και της ομαδοποίησης των υποκειμένων στις δύο ηλικιακές ομάδες.

### 5.1 Πειραματικές HEG καταγραφές

Αρχικά, για την εφαρμογή των μεθόδων, έπρεπε να κατασκευασθούν οι δυναμικοί γράφοι από πραγματικά σήματα EEG. Έτσι, χρησιμοποιήθηκε μια βάση, η οποία περιείχε σήματα από 109 διαφορετικά άτομα, όταν εκείνα ήταν σε διάφορες καταστάσεις (states) [21]. Στη παρούσα διπλωματική χρησιμοποιήθηκαν EEG από δύο καταστάσεις, στη μία κατάσταση κάθε υποκείμενο είχε ανοιχτά τα μάτια του κατά τη δειγματοληψία του EEG (eyes open) και στην άλλη τα μάτια του ήταν κλειστά (eyes closed) σε κατάστασεις ηρεμίας (resting state). Η δειγματοληψία στα πραγματικά σήματα EEG ήταν  $f_s = 160$  δείγματα/δευτερόλεπτο σε 64 κανάλια και καταγραφή ενός λεπτού. Δυστυχώς, υπήρχαν πληροφορίες για την ηλικία και το φύλο σε 94 υποκείμενα, οπότε χρησιμοποιήθηκαν τα σήματα από αυτά τα άτομα. Στον πίνακα 5.1 φαίνονται τα πλήθη των υποκειμένων σε κάθε ηλικία.

19	20	22	23	24	25	26	27	28	30	31	32	33	34	36	37	38	39
2	1	0	1	1	1	2	3	1	4	2	1	1	1	2	0	0	1
2	1	1	2	0	1	2	3	1	0	2	4	1	3	2	1	2	2
40	41	42	43	44	45	46	47	48	49	50	51	52	53	54	55	56	57
0	0	0	2	3	0	0	1	1	0	1	0	2	1	1	0	0	2
1	1	2	1	2	1	1	2	3	2	2	4	0	0	1	2	1	0
58	59	67															
0	1	1															
1	0	0															

**Πίνακας 5.1: Πλήθος υποκειμένων σε κάθε ηλικία. Με μπλε φαίνονται τα αρσενικά υποκείμενα, ενώ με κόκκινο φαίνονται τα θηλυκά.**

## 5.2 Κατασκευή δυναμικών γράφων

Αρχικά, έγινε ο υπολογισμός των δυναμικών γράφων χρησιμοποιώντας την σύζευξη συχνοτήτων φάσης πλάτους (PAC-CFC), καθώς και την ενδοσυζευξη (intra FC) και στις δύο καταστάσεις. Οι συχνότητες σύζευξης ήταν οι :

- $\delta$  (1 – 4 Hz)
- $\theta$  (4 – 8 Hz)
- $\alpha_1$  (8 – 10 Hz)
- $\alpha_2$  (10 – 13 Hz)
- $\beta_1$  (13 – 20 Hz)
- $\beta_2$  (20 – 30 Hz)
- $\gamma_1$  (30 – 48 Hz)
- $\gamma_2$  (52 – 75 Hz)

Έτσι, για κάθε μία από τις οχτώ συχνότητες, υπολογίστηκαν οι δυναμικοί γράφοι σε ένα παράθυρο ίσο με  $2f_s$  και ένα βήμα πέντε σημείων (όπου προέκυψαν 1856 χρονικά σημεία) με την μέθοδο της ενδοσυζευξης, με αποτέλεσμα να δημιουργηθούν πίνακες μεγέθους  $8 \times 1856 \times 64 \times 64$  σε καθένα υποκείμενο. Με παρόμοιο τρόπο κατασκευάστηκαν οι δυναμικοί γράφοι και με την μέθοδο του CFC, από την οποία δημιουργήθηκαν πίνακες μεγέθους  $8 \times 8 \times 1856 \times 64 \times 64$ . Ουσιαστικά, ο συνολικός αριθμός συζεύξεων μεταξύ συχνοτήτων στο PAC-CFC είναι  $\frac{8 \times 7}{2} = 28$ . Και στις δύο τεχνικές χρησιμοποιήθηκε το IPLV, προκειμένου να προσεγγιστεί η ισχύς της σύζευξης συχνοτήτων. Έπειτα, για κάθε συνδυασμό αισθητήρων  $j$  και  $k$  για  $j \neq k$ , καθώς και σε κάθε χρονική στιγμή (slide), ανιχνεύονται η τιμή και η συχνότητα, η οποία δίνει τη μέγιστη τιμή του IPLV. Αυτή η ανίχνευση προκύπτει από την σύγκριση των δυναμικών γράφων του CFC και της ενδοσυζευξης. Συγκεκριμένα, τα βήματα για τον υπολογισμό της μέγιστης τιμής του IPLV φαίνονται παρακάτω :

Βήμα 1: Υπολογισμός της μέγιστης τιμής του IPLV, καθώς και της συχνότητας που αντιστοιχεί σε αυτήν, από την κατεύθυνση από τον κόμβο  $j$  στον  $k$ , στον γράφο του CFC.

Βήμα 2 : Υπολογισμός της μέγιστης τιμής του IPLV, καθώς και της συχνότητας που αντιστοιχεί σε αυτήν, από την κατεύθυνση από τον κόμβο  $k$  στον  $j$ , στον γράφο του CFC.

Βήμα 3 : Υπολογισμός της μέγιστης τιμής του IPLV, καθώς και της συχνότητας που αντιστοιχεί σε αυτήν από την κατεύθυνση από τον κόμβο  $j$  στον  $k$ , στον γράφο της ενδοσυζευξης.

Βήμα 4 : Υπολογισμός της ολικής μέγιστης τιμής από τις τρεις μέγιστες τιμές βρέθηκαν στα προηγούμενα βήματα και της συχνότητας που αντιστοιχεί σε αυτήν.

Ο τελικός πίνακας που προκύπτει έχει μέγεθος  $υποκείμενα \times 2 \times slides \times 64 \times 64$ , όπου το πρώτο μήκος της δεύτερης διάστασης δηλώνει την μέγιστη τιμή του IPLV και το δεύτερο μήκος δηλώνει την συχνότητα που αντιστοιχεί σε αυτή. Τα μέγιστα σε κάθε δυναμικό γράφο υπολογίζονται και για τις δύο καταστάσεις. Σε αυτόν τον πίνακα εφαρμόστηκε ο μετασχηματισμός weighted information exchange ratio (wier) [6], ο οποίος ορίζεται ως εξής:

- Υπολογισμός της μέσης τιμής μεταξύ της χαμηλής και της υψηλής συχνότητας κάθε ρυθμού (4 – 8 Hz)
- Υπολογισμός του πηλίκου της μέσης τιμής του υψηλού ρυθμού ως προς τη μέση τιμή του χαμηλού ρυθμού (δηλαδή για κάθε σύζευξη), ο πίνακας που προκύπτει έχει 36 τιμές. Οι πρώτες οχτώ τιμές του πίνακα είναι ίσες με 1.
- Πολλαπλασιασμός της μέγιστης τιμής του IPLV με το πηλίκο που υπολογίστηκε στο προηγούμενο βήμα για τη συχνότητα που αντιστοιχείται σε αυτή.

Στον παρακάτω ψευδοκώδικα υπολογίζεται ο μετασχηματισμός wier

Αλγόριθμος 5.1-Υπολογισμός μετασχηματισμού wier
1. Αρχικοποίηση του πίνακα $freqs=[1\ 4 ; 4\ 8 ; 8\ 10 ; 10\ 13 ; 13\ 20 ; 20\ 30 ; 30\ 48 ; 52\ 75]$
2. Αρχικοποίηση του πίνακα ratio (οι οχτώ πρώτες τιμές του θα είναι ίσες με 1)
3. Αρχικοποίηση του πίνακα $mean\_values$
4. Αρχικοποίηση του πίνακα $dynamic\_max\_weighted$
5. Για κάθε $i= 1$ ως 8
6. $mean\_values(i)=(freqs(i, 1) + freqs(i, 2))/2$
7. τέλος του βρόγχου
8. $s= 9$
9. Για κάθε $i= 1$ ως 8
10. Για κάθε $j= i+1$ ως 8
11. $ratio(s)= mean\_values(j)/mean\_values(i)$
12. τέλος του δεύτερου βρόγχου
13. τέλος του πρώτου βρόγχου
14. Για κάθε $su= 1$ ως 94
15. Για κάθε $slide= 1$ ως 1856
16. Για κάθε $i= 1$ ως 64
17. Για κάθε $j= i+1$ ως 64
18. Αν το μέγιστο βρίσκεται στο $dynamic\_max(su, 1, slide, i, j)$
19. $temp\_sensor1= i$
20. $temp\_sensor2= j$
21. Αλλιώς
22. $temp\_sensor1= j$
23. $temp\_sensor2= i$
24. Τέλος συνθήκης
25. $max\_index= dynamic\_max(su, 2, slide, temp\_sensor1, temp\_sensor2)$
26. $dynamic\_max\_weighted(su, 1, slides, temp\_sensor1, temp\_sensor2)= ratio(max\_index)* dynamic\_max\_weighted(su, 1, slides, temp\_sensor1, temp\_sensor2)$
27. Τέλος τέταρτης συνθήκης
28. Τέλος τρίτης συνθήκης
29. Τέλος δεύτερης συνθήκης
30. Τέλος της πρώτης συνθήκης

Επιπρόσθετα, για κάθε ένα υποκείμενο και για κάθε slide, υπολογίζεται η καθολική απόδοση στα IPLV του γράφου. Ο λόγος που γίνεται αυτό είναι για να μπορεί να εκτιμηθεί το κατά πόσο μπορεί να στέλνει πληροφορία η κάθε περιοχή του εγκεφάλου, στην οποία ήταν συνδεδεμένο ένα ηλεκτρόδιο. Ο πίνακας που προέκυψε είχε μέγεθος  $64 \times 1856 \times 94$ , όπου 64 είναι ο συνολικός αριθμός των κόμβων στον γράφο, όπως αναφέρθηκε προηγουμένως. Στην εικόνα 5.1, φαίνονται οι τοπογραφικές τοπολογίες της εγκεφαλικής συνδεσιμότητας στο πρώτο υποκείμενο, ενώ στις εικόνες 5.2 και 5.3 παρουσιάζονται οι

τιμές της καθολικής απόδοσης για τις έξι πρώτες χρονικές στιγμές, για το πρώτο υποκείμενο σε κατάσταση ανοιχτών και κλειστών ματιών αντίστοιχα.

Στην καθολική απόδοση του γράφου χρησιμοποιήθηκε ο αλγόριθμος NNMF. Επειδή όμως ο NMF εφαρμόζεται σε τένσορες δύο διαστάσεων, έπρεπε να συμπίεσει ο πίνακας της καθολικής απόδοσης σε μέγεθος  $64 \times (1856 \times 94) = 64 \times 174464$ . Επίσης, θεωρήθηκε αναγκαίο να βρεθεί αρχικά η διάσταση  $k$  των δύο παραγόντων, η οποία ελαχιστοποιεί το μέσο σφάλμα του NNMF. Για παράδειγμα, Αν  $Y$  είναι ένας πίνακας μεγέθους  $I \times T$  τότε θα πρέπει να βρεθούν δύο πίνακες  $A$  (με μέγεθος  $I \times k$ ) και  $X$  (με μέγεθος  $k \times T$ ), τέτοιοι ώστε :

$$Y = AX \quad (5.1)$$

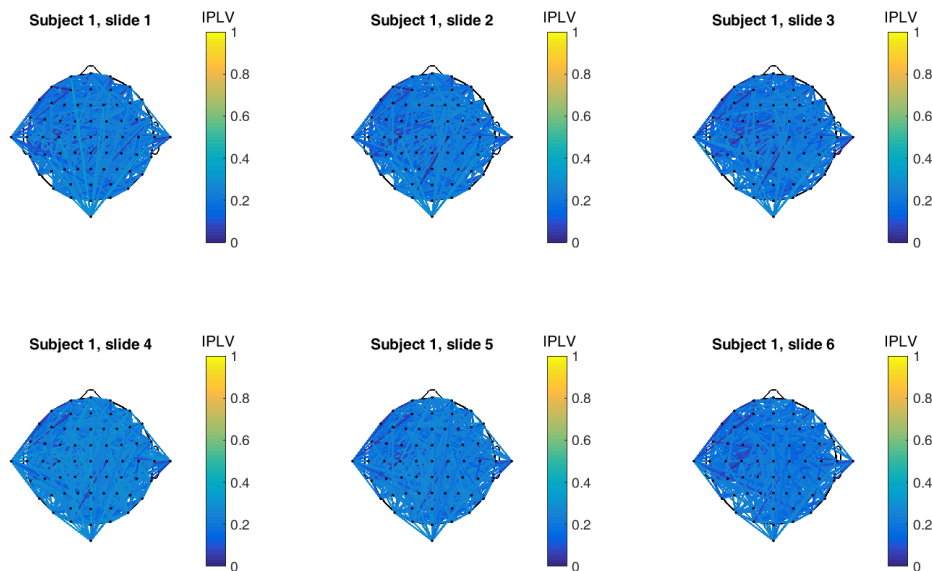
Με το μέσο σφάλμα να ορίζεται ως :

$$\text{μέσο σφάλμα} = \frac{\sum_{i=1}^I \sum_{j=1}^T Y - AX}{IT} \quad (5.2)$$

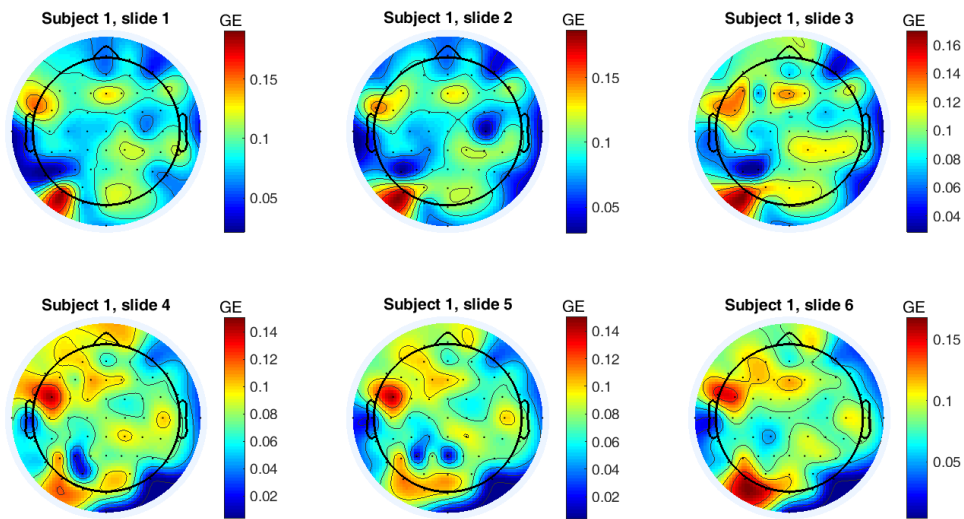
Έτσι, πρέπει να βρεθεί το  $k$ , το οποίο ελαχιστοποιεί ή δίνει ένα αρκετά μικρό σφάλμα. Η εικόνα 5.4 δείχνει το γράφημα του μέσου σφάλματος σε συνάρτηση με το  $k$ . Το μικρότερο σφάλμα που πετυχαίνεται είναι για  $k = 35$ , με τιμή 0.018. Επειδή όμως ο αλγόριθμος του NNMF καθυστερεί αρκετά όσο αυξάνεται το  $k$ , επιλέχθηκε τελικά το  $k = 2$ , το οποίο δίνει ένα ικανοποιητικό σφάλμα με τιμή 0.034.

Εφόσον υπολογίστηκε το γινόμενο του  $AX$ , αυτός ο πίνακας εισήχθη στον αλγόριθμο του neural gas. Σε αυτήν την περίπτωση πρέπει να επιλεγεί το πλήθος των κλάσεων (μικροκαταστάσεις), στο οποίο σταθεροποιείται το σφάλμα μεταξύ των prototypes και του αρχικού πίνακα. Στην εικόνα 5.5 φαίνεται το γράφημα του σφάλματος του neural gas για διάφορα πλήθη μικροκαταστάσεων. Όπως φαίνεται στο γράφημα, το σφάλμα σταθεροποιείται, όταν υπάρχουν οχτώ μικροκαταστάσεις.

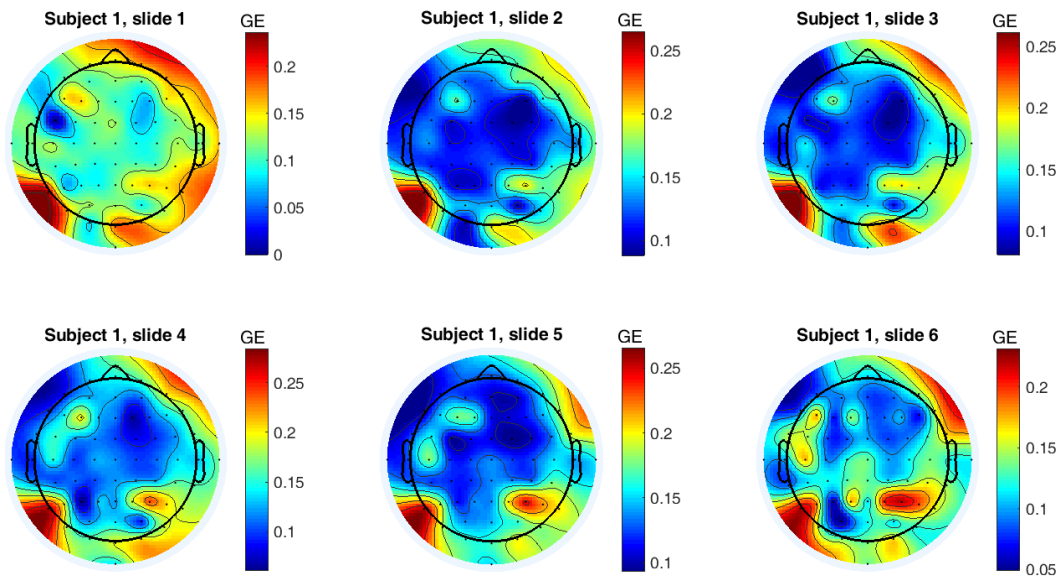
Συνοψίζοντας, εισάγοντας την καθολική απόδοση του δυναμικού γράφου στον συνδυασμό NMF - vector quantization (NNMF-VQ), εξάγεται ο πίνακας των συμβόλων ή αλλιώς ο πίνακας των μικροκαταστάσεων. Ο πίνακας αυτός έχει διάσταση ίση με υποκείμενα  $\times$  slides, ενώ οι τιμές του κυμαίνονται από 1 ως  $g$ , όπου  $g$  είναι το πλήθος των code-books που χρησιμοποιήθηκε, δηλαδή οχτώ [22]. Στα επόμενα υποκεφάλαια, παρουσιάζονται τα μετρικά που χρησιμοποιήθηκαν στην εργασία.



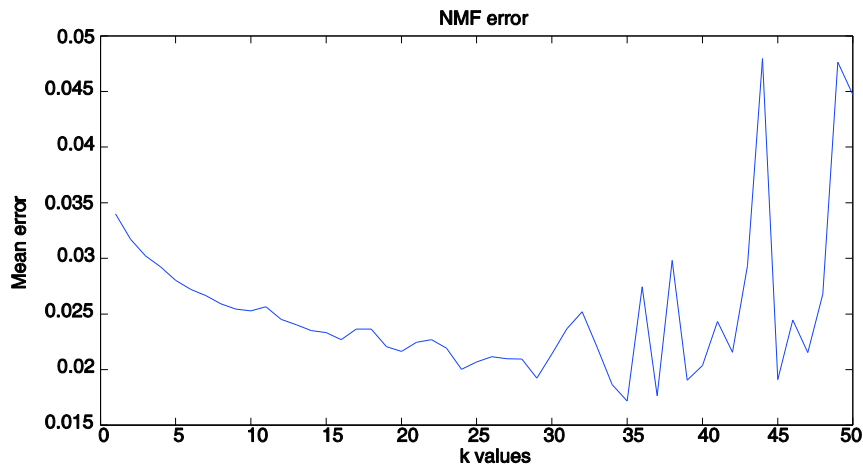
**Εικόνα 5.1: Τοπογραφικές απεικονίσεις της εγκεφαλικής συνδεσιμότητας από το πρώτο υποκείμενο στις έξι πρώτες χρονικές στιγμές (slides) σε κατάσταση ανοιχτών ματιών**



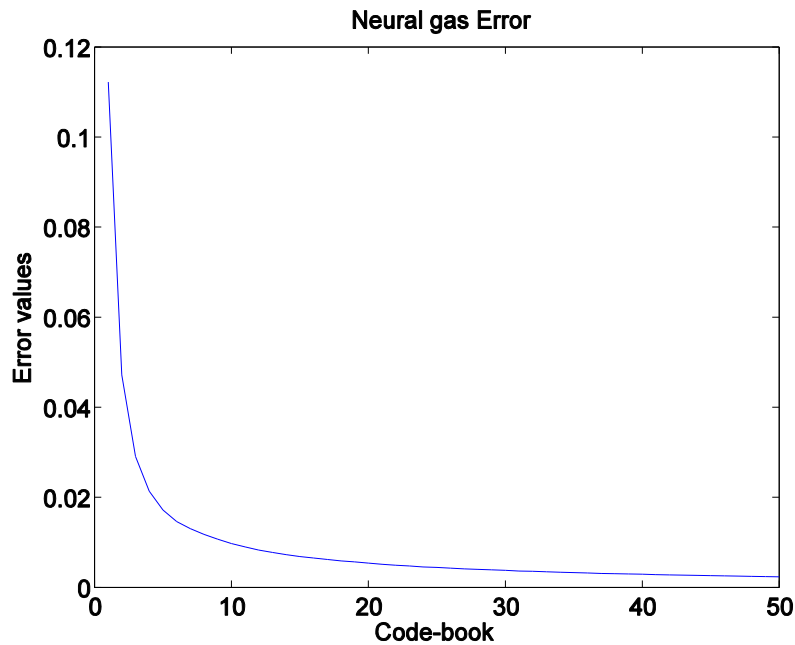
**Εικόνα 5.2: Τοπογραφικές απεικονίσεις της καθολικής απόδοσης από το πρώτο υποκείμενο στις έξι πρώτες χρονικές στιγμές (slides) σε κατάσταση ανοιχτών ματιών**



**Εικόνα 5.3: Τοπογραφικές απεικονίσεις της καθολικής απόδοσης από το πρώτο υποκείμενο στις έξι πρώτες χρονικές στιγμές (slides) σε κατάσταση κλειστών ματιών**



**Εικόνα 5.4: Μέσο σφάλμα του NMF σε συνάρτηση με το k**



**Εικόνα 5.5: Σφάλμα του neural gas**

### 5.3 Μετρικά που χρησιμοποιήθηκαν

Εφόσον υπολογίστηκαν τα σύμβολα από τον αλγόριθμο NMF-VQ, εξήχθησαν διάφορα μετρικά, τα οποία χρησιμοποιήθηκαν ως είσοδοι στον ταξινομητή ELM, προκειμένου να γίνει πρόβλεψη της ηλικίας. Αυτά τα μετρικά παρουσιάζονται στα παρακάτω υποκεφάλαια.

#### 5.3.1 Ποσοστά μεταβάσεων

Ως μετάβαση ορίζεται η αλλαγή από μία κατάσταση σε μία άλλη μέσα σε δύο χρονικές στιγμές. Για παράδειγμα, αν σε μια χρονική στιγμή  $t_0$  η κατάσταση είναι  $a$ , ενώ την χρονική στιγμή  $t_1$  η κατάσταση είναι  $b$  με  $a \neq b$ , θα υπάρχει μία μετάβαση από την  $t_0$  στην  $t_1$ . Αρχικά, για κάθε υποκείμενο υπολογίστηκε το ποσοστό των μεταβάσεων (δηλαδή το πλήθος των μεταβάσεων διαιρεμένο με τον αριθμό των slides-1), στον πίνακα συμβόλων του NMF-VQ.



Έπειτα, δύο άλλα χαρακτηριστικά που χρησιμοποιήθηκαν ήταν η συχνότητα εμφάνισης μεταβάσεων ανά συνδυασμό συμβόλων, καθώς και το ποσοστό μεταβάσεων των συχνοτήτων στους δυναμικούς γράφους για κάθε συνδυασμό κόμβων. Στις συχνότητες εμφάνισης μεταβάσεων υπολογίζεται το πλήθος των μεταβάσεων μεταξύ δύο διαφορετικών μικροκαταστάσεων, διαιρεμένο με  $slides - 1$ . Το ποσοστό μεταβάσεων μεταξύ συχνοτήτων σχετίζεται με τις μεταβάσεις μεταξύ συχνοτήτων για κάθε συνδυασμό κόμβων δυναμικό γράφο. Παρακάτω φαίνονται οι ψευδοκώδικες για τον υπολογισμό του κάθε χαρακτηριστικού.

<p>Αλγόριθμος 5.3-Υπολογισμός των συνολικών μεταβάσεων μεταξύ δύο διαφορετικών κλάσεων</p> <ol style="list-style-type: none"> <li>1. Αρχικοποίηση του πίνακα των συμβόλων (<i>transitions_8_8</i>)</li> <li>2. Για κάθε <i>su</i> από 1 ως <i>subjects</i>, επανέλαβε</li> <li>3. Για κάθε <i>i</i> από 1 ως 1856 - 1</li> <li>4. <math>transitions\_8\_8(su, symbols(i), symbols(i+1)) = transitions\_8\_8(su, symbols(i), symbols(i+1)) + 1</math></li> <li>5. τέλος του δευτέρου βρόγχου</li> <li>6. τέλος του πρώτου βρόγχου</li> </ol>
<p>Αλγόριθμος 5.4-Υπολογισμός μεταβάσεων μεταξύ δύο διαφορετικών συχνοτήτων στους δυναμικούς γράφους</p> <ol style="list-style-type: none"> <li>1. Αρχικοποίηση του πίνακα των συμβόλων (<i>transitions_64_64</i>)</li> <li>2. Για κάθε <i>su</i> από 1 ως <math>length(subjects)</math>, επανέλαβε</li> <li>3. Για κάθε <i>i</i> από 1 ως 64</li> <li>4. Για κάθε <i>j</i> από 1 ως 64</li> <li>5. Για κάθε <i>sl</i> από 1 ως 1856 - 1</li> <li>6. <math>dynamic\_graph(su, 2, sl + 1, i, j) \neq dynamic\_graph(su, 2, sl, i, j)</math></li> <li>7. <math>transitions\_64\_64(su, i, j) = transitions\_64\_64(su, i, j) + 1</math></li> <li>8. τέλος της συνθήκης</li> <li>9. τέλος του τρίτου βρόγχου</li> <li>10. τέλος του δευτέρου βρόγχου</li> <li>11. τέλος του πρώτου βρόγχου</li> </ol>

### 5.3.2 Δείκτης πολυπλοκότητας

Ο δείκτης πολυπλοκότητας εκφράζει το πλήθος των διακριτών συμβολοσειρών (substrings), τα οποία βρίσκονται μέσα σε μια μεγαλύτερη συμβολοσειρά (string). Μία συμβολοσειρά με μικρό δείκτη πολυπλοκότητας συνήθως περιέχει έναν μεγάλο αριθμό από επαναλαμβανόμενα substrings. Παρόλο αυτά, προκειμένου να γίνει κατηγοριοποίηση των συμβολοσειρών με μικρό δείκτη πολυπλοκότητας, θα πρέπει να καθοριστεί ποιος είναι ο μέσος, καθώς και ο μέγιστος δείκτης πολυπλοκότητας [23].

Γενικά, σε διάφορες κατηγορίες προβλημάτων, ο στόχος είναι να καθοριστεί αν ένα string *x*, έχει στατιστικά σημαντικό δείκτη πολυπλοκότητας. Ένα παράδειγμα, ενός μετρικού που μπορεί να υπολογίσει τη σημαντικότητα αυτού του μετρικού για ένα string *x*, φαίνεται παρακάτω :

$$s(x) = c(x) - \max\{C_{n,k}\} = c(x) - \sum_{i=1}^n \min\{k^i, n - i + 1\} \quad (5.3)$$

όπου  $s(x)$  είναι το σκορ που εκφράζει το πόσο στατιστικά σημαντικός είναι ο δείκτης πολυπλοκότητας,  $n$  είναι το μέγεθος του string και  $c(x)$  είναι η τιμή του δείκτη πολυπλοκότητας. Επίσης,  $C_{n,k}$  είναι μία τυχαία μεταβλητή που σχετίζεται με τον συνολικό αριθμό των substrings σε ένα string μεγέθους  $n$  από ένα σύνολο  $k$  γραμμάτων. Με αυτήν τη μέθοδο συγκρίνεται η πολυπλοκότητα  $c(x)$  με την μέγιστη δυνατή πολυπλοκότητα  $C_{n,k}$ . Παρόλο αυτά, αυτός ο τρόπος υπολογισμού της στατιστικής σημαντικότητας του δείκτη πολυπλοκότητας δεν συμπεριλαμβάνει την κατανομή που μπορεί να έχει το  $C_{n,k}$ . Μία πιο στατιστική προσέγγιση, η οποία περιλαμβάνει και την στατιστική κατανομή του  $C_{n,k}$ , φαίνεται παρακάτω:

$$z(x) = \frac{c(x) - E(C_{n,k})}{\sqrt{Var(C_{n,k})}} \quad (5.4)$$

όπου  $E\{\}$  και  $Var\{\}$  εκφράζουν την μέση τιμή και τη διακύμανση αντίστοιχα.

Στη παρούσα εργασία, ο δείκτης πολυπλοκότητας εφαρμόζεται στις κλάσεις που προκύπτουν από τον αλγόριθμο του neural gas. Ουσιαστικά δείχνει το κατά πόσο συχνά εμφανίζονται μία ή περισσότερες μικροκαταστάσεις σε ένα υποκείμενο κατά τη διάρκεια του χρόνου. Παρακάτω φαίνεται ο ψευδοκώδικας για τον υπολογισμό του δείκτη πολυπλοκότητας.

Αλγόριθμος 5.5-Υπολογισμός του δείκτη πολυπλοκότητας
<ol style="list-style-type: none"> <li>1. Αρχικοποίηση του πίνακα <i>complexity_index</i></li> <li>2. Για κάθε <i>su</i> από 1 ως 94</li> <li>3. Για κάθε <i>i</i> από 2 ως 7</li> <li>4. <i>complexity_index(su, i)</i> = <i>sequencecomplexity(symbols(su, 1:slides), i)</i></li> <li>5. τέλος του δεύτερου βρόγχου</li> <li>6. τέλος του πρώτου βρόγχου</li> </ol>

Η συνάρτηση *sequencecomplexity(x, k)* υπολογίζει τον δείκτη πολυπλοκότητας ενός string *x*, με *k* μέγεθος substring.

### 5.3.3 Ενδεικτική εντροπία

Η ενδεικτική εντροπία (sample entropy) είναι μία παραλλαγή της προσεγγιστικής εντροπίας (approximate entropy). Η προσεγγιστική εντροπία, όπως και ο δείκτης πολυπλοκότητας, εκφράζει τις επαναλαμβανόμενες χρονοσειρές, οι οποίες βρίσκονται σε μία μεγαλύτερη χρονοσειρά. Μία χρονοσειρά *r*, η οποία περιέχει πολλές επαναλαμβανόμενες χρονοσειρές έχει σχετικά χαμηλή εντροπία, ενώ σε αντίθετη περίπτωση έχει υψηλή εντροπία. Αν η *r* έχει μέγεθος *N*, πρέπει να επιλεγθούν δύο μεταβλητές *dim* και *s*, όπου η πρώτη αντιστοιχεί στο μέγεθος μιας μικρότερης χρονοσειράς, ενώ η δεύτερη είναι το κριτήριο ομοιότητας. Επίσης, ως  $p_m(i)$  ονομάζεται της χρονοσειράς μεγέθους *m* που ξεκινάει από τη *i*-οστή θέση του *r*. Το συνολικό πλήθος των  $p_m$  είναι  $N - m + 1$ . Σύμφωνα με τα προηγούμενα, ορίζεται η παρακάτω ποσότητα [24] :

$$C_{im} = \frac{n_{im}(r)}{N-m+1} \quad (5.5)$$

όπου  $n_{im}(r)$  είναι το πλήθος των χρονοσειρών, οι οποίες είναι όμοιες (η διαφορά τους δεν έχει απόσταση μεγαλύτερη από *s*) με το  $p_m(i)$ . Επιπρόσθετα, ως  $C_m$  θεωρείται ο μέσος όρος όλων των  $C_{im}$ . Τέλος, η προσεγγιστική εντροπία θα είναι ίση με :

$$\text{Approximate\_entropy} = \ln \frac{C_m(r)}{C_{m+1}(r)} \quad (5.6)$$

Όσον αφορά, την ενδεικτική εντροπία, αυτή έχει δύο βασικές διαφορές με την προσεγγιστική εντροπία [25] :

- Δεν περιλαμβάνει αυτό-ταιριάσματα, δηλαδή συγκρίσεις μεταξύ του  $p_m(i)$  και του  $p_m(i)$ .
- Δεν εξαρτάται τόσο πολύ στο μέγεθος των δεδομένων όσο η προσεγγιστική εντροπία.

Για κάθε υποκείμενο και κάθε slide υπολογίστηκε το άθροισμα των βαρών του δυναμικού γράφου, στον οποίο είχε εφαρμοστεί ο αλγόριθμος κατωφλίου. Ο πίνακας που προέκυψε είχε μέγεθος υποκείμενα × slides. Προκειμένου να χρησιμοποιηθεί η εντροπία σαν χαρακτηριστικό, έπρεπε να καθοριστεί ποια θα ήταν η τιμή του *dim*. Για να γίνει αυτό, υπολογίστηκε η συσχέτιση μεταξύ του χαρακτηριστικού και της πραγματικής ηλικίας κάθε υποκειμένου. Γενικά μία τέτοια συσχέτιση μεταξύ δύο μεταβλητών *A* και *B* μπορεί να υπολογιστεί με τον τύπο του Pearson:

$$\rho(A, B) = \frac{\sum_{n=1}^N \left( \frac{A_i - \mu_A}{\sigma_A} \right) \left( \frac{B_i - \mu_B}{\sigma_B} \right)}{N-1} \quad (5.7)$$

Έτσι, δοκιμάστηκαν μεγέθη του  $dim$  από 2 ως και 15 και υπολογίστηκαν οι σταθερές συσχέτισης για κάθε μία τιμή του  $dim$ . Η μεγαλύτερη συσχέτιση που υπήρξε ήταν για  $dim = 5$ . Εφόσον είχε καθοριστεί το πόσο θα ήταν η τιμή του  $dim$ , υπολογίστηκαν οι ενδεικτικές εντροπίες για κάθε υποκείμενο.

#### Αλγόριθμος 5.6-Υπολογισμός της ενδεικτικής εντροπίας

1. Αρχικοποίηση του πίνακα *entropy*
2. Αρχικοποίηση του πίνακα *sum\_weights*
3. Για κάθε *su* από 1 ως 94
4. Για κάθε *slide* από 1 ως 1856
5. Για κάθε *i* από 1 ως 64
6. Για κάθε *j* από 1 ως 64
7.  $sum\_weights(su, slide) = sum\_weights(su, slide) + dynamic\_max\_weights\_threshold(su, slide, i, j)$
8. τέλος του τέταρτου βρόγχου
9. τέλος του τρίτου βρόγχου
10. τέλος του δεύτερου βρόγχου
11. τέλος του πρώτου βρόγχου
12. Για κάθε *su* από 1 ως 94
13.  $entropy(su) = SampEn(sum\_weights(su, 1:slides), 5, 0.2 * std(sum\_weights(su, 1:slides)))$
14. τέλος πρώτου βρόγχου

Η συνάρτηση  $SampEn(x, dim, s)$  υπολογίζει την ενδεικτική εντροπία για μία χρονοσειρά  $x$  με μέγεθος μικρότερον χρονοσειρών  $dim$  και με δείκτη ομοιότητας  $s$ . Ο δείκτης ομοιότητας που επιλέχθηκε ήταν ίσος με  $0.2 * std(x)$ , όπου  $std()$  δηλώνει την τυπική απόκλιση.

### 5.3.4 Ιστόγραμμα συχνότητων

Το ιστόγραμμα των συχνότητων δείχνει το πλήθος των τιμών που αντιστοιχούν σε μία συχνότητα στον πίνακα των μεγίστων στους δυναμικούς γράφους. Όπως αναφέρθηκε προηγουμένως, υπήρχαν συνολικά 36 συχνότητες, 8 συχνότητες από την ενδοσύζευξη και 28 από το CFC. Για κάθε υποκείμενο, υπολογίστηκε το ιστόγραμμα των συχνότητων που αντιστοιχεί σε αυτό.

#### Αλγόριθμος 5.7-Υπολογισμός του ιστογράμματος συχνότητων

1. Αρχικοποίηση του πίνακα *histogram*
2. Για κάθε *su* από 1 ως 94
3. Για κάθε *r* από 1 ως 36
4. Για κάθε *sl* από 1 ως 1856
5. Για κάθε *i* από 1 ως 64
6. Για κάθε *j* από 1 ως 64
7.  $Av\ r == dynamic\_max(su, 2, sl, i, j)$
8.  $histogram(su, r) = histogram(su, r) + 1$
9. τέλος της συνθήκης
10. τέλος πέμπτου βρόγχου
11. τέλος τέταρτου βρόγχου
12. τέλος τρίτου βρόγχου
13. τέλος δεύτερου βρόγχου
14. τέλος πρώτου βρόγχου

### 5.3.5 Μαρκοβιανές αλυσίδες και ποσοστό εντροπίας σε αυτές

Μία στοχαστική διαδικασία  $\{X_i\}$  είναι μία αριθμημένη ακολουθία τυχαίων μεταβλητών, στην οποία μπορεί να υπάρχει μία τυχαία εξάρτηση μεταξύ αυτών. Αυτή η εξάρτηση χαρακτηρίζεται από τη κοινού πιθανότητα των συναρτήσεων μάζας (joint probability mass function):

$$P_r\{(X_1, X_2, \dots, X_n) = x_1, x_2, \dots, x_n\} = p(x_1, x_2, \dots, x_n), \text{ για } (x_1, x_2, \dots, x_n) \in R^n \quad (5.8)$$

Επιπρόσθετα, μία στοχαστική διαδικασία είναι σταθερή (stationary), αν η από κοινού κατανομή, ενός οποιοδήποτε υποσυνόλου της ακολουθίας των τυχαίων μεταβλητών είναι αμετάβλητη ως προς τις μεταβολές του χρόνου, δηλαδή:

$$P_r\{X_1 = x_1, X_2 = x_2, \dots, X_n = x_n\} = P_r\{X_{1+k} = x_{1+k}, X_{2+k} = x_{2+k}, \dots, X_{n+k} = x_{n+k}\} \quad (5.9)$$

Σε αυτή την περίπτωση η από κοινού πιθανότητα της συνάρτησης μάζας των τυχαίων μεταβλητών μπορεί να γραφεί ως:

$$p(x_1, x_2, \dots, x_n) = p(x_1)p(x_2|x_1)p(x_3|x_2) \dots p(x_n|x_{n-1}) \quad (5.10)$$

Μία μαρκοβιανή αλυσίδα ονομάζεται χρονικά αμετάβλητη αν η υπό συνθήκη πιθανότητα  $p(x_{n+1}|x_n)$  δεν εξαρτάται από τον δείκτη  $n$ , δηλαδή:

$$P_r\{X_{n+1} = b|X_n = a\} = P_r\{X_{n+1} = b|X_n = a\}, \text{ για κάθε } a \text{ και } b \in X \quad (5.11)$$


Επίσης, αν  $\{X_i\}$  είναι μία μαρκοβιανή αλυσίδα, τότε η μεταβλητή  $X_n$  ονομάζεται κατάσταση τη χρονική στιγμή  $n$ . Μία χρονικά αμετάβλητη μαρκοβιανή αλυσίδα χαρακτηρίζεται από την αρχική της κατάσταση και τον πίνακα μετάβασης πιθανότητας  $P = [P_{ij}]$ ,  $i, j \in \{1, 2, \dots, r\}$  όπου  $P_{ij} = P_r\{X_{n+1} = j|X_n = i\}$ . Αν είναι εφικτή η μετάβαση από οποιαδήποτε κατάσταση της μαρκοβιανής αλυσίδας σε μια άλλη, τότε η μαρκοβιανή αλυσίδα ονομάζεται αμείωτη (irreducible). Επιπρόσθετα, αν η πιθανότητα της συνάρτησης μάζας της τυχαίας μεταβλητής τη χρονική στιγμή  $n$ , είναι  $p(x_n)$ , η πιθανότητα της συνάρτησης μάζας τη χρονική στιγμή  $n + 1$  είναι:

$$p(x_{n+1}) = \sum_{x_n} p(x_n)P_{x_n, x_{n+1}} \quad (5.12)$$

Θεωρώντας μία μαρκοβιανή αλυσίδα δύο καταστάσεων, αυτή μπορεί να περιγραφεί με τον παρακάτω πίνακα:

$$P = \begin{bmatrix} 1 - \alpha & \alpha \\ \beta & 1 - \beta \end{bmatrix} \quad (5.13)$$

Στην εικόνα 5.6 φαίνεται αυτή η μαρκοβιανή αλυσίδα.



**Εικόνα 5.6: Μαρκοβιανή αλυσίδα δύο καταστάσεων**

Η εντροπία (entropy) είναι ένα μέτρο, το οποίο μπορεί να εκτιμήσει την αβεβαιότητα που έχει μια τυχαία μεταβλητή. Αν  $X$  είναι μια τυχαία μεταβλητή, τότε η εντροπία ορίζεται ως:

$$H(X) = -\sum_{x \in X} p(x) \log p(x) \quad (5.14)$$

Η εντροπία μπορεί να επεκταθεί και σε ζεύγη τυχαίων μεταβλητών. Σε αυτή την περίπτωση ονομάζεται από κοινού εντροπία (joint entropy) και ορίζεται ως:

$$H(X, Y) = -\sum_{x \in X} \sum_{y \in Y} p(x, y) \log p(x, y) \quad (5.15)$$

Όσον αφορά την εντροπία μιας στοχαστικής διαδικασίας  $\{X_i\}$ , αυτή μπορεί να οριστεί ως:

$$H(\bar{X}) = \lim_{n} \frac{H(X_1, X_2, \dots, X_n)}{n} \quad (5.16)$$

Εφόσον το όριο της (5.8) υπάρχει, αυτή μπορεί να γραφθεί ως [26]:

$$H(\bar{X}) = -\sum_{i,j} \mu_i P_{ij} \log P_{ij} \quad (5.17)$$

όπου  $\mu$  είναι η λύση της εξίσωσης:

$$\mu_j = \sum_i \mu_i P_{ij} \quad (5.18)$$

Έτσι, τα διανύσματα των μικροκαταστάσεων μπορούν να μοντελοποιηθούν ως μια «κρυφή» μαρκοβιανή αλυσίδα για κάθε υποκείμενο. Εφόσον εξήχθηκε ο πίνακας μετάβασης  $P_{ij}$ , υπολογίστηκε το ποσοστό εντροπίας μαρκοβιανών αλυσίδων. Ο πίνακας που προκύπτει έχει μέγεθος subjects  $\times$  8  $\times$  8.

#### Αλγόριθμος 5.8- Υπολογισμός του ποσοστού εντροπίας στις μαρκοβιανές αλυσίδες

1. Αρχικοποίηση του πίνακα *markov\_entropy\_rate*
2. Αρχικοποίηση του πίνακα *temp\_array*
3.  $s = 1$
4. Για κάθε  $su$  από 1 ως 94
5. Για κάθε  $i$  από 1 ως 1856
6. Αν δεν υπάρχει το στοιχείο *symbols(su, i)* στον πίνακα *temp\_array*
7. *temp\_array(s) = symbols(su, i)*
8.  $s = s + 1$
9. τέλος συνθήκης
10. τέλος του δεύτερου βρόγχου
11.  $s = 1$
12. Για κάθε  $i$  από 1 ως 8
13. Αν το  $i$  δεν υπάρχει στο *temp\_array*
14. *symbols(su, end+1) = i*
15. τέλος συνθήκης
16. *markov\_entropy\_rate(1, 1:8, 1:8) = markov\_chain\_sts(symbols(su, 1:1856))*
17. τέλος του πρώτου βρόγχου

## 5.4 Περιγραφή επιλογής χαρακτηριστικών

Εφόσον καθορίστηκαν τα χαρακτηριστικά που θα χρησιμοποιηθούν επιλέχθηκαν αυτά που έδιναν τη μεγαλύτερη σταθερά συσχέτισης σύμφωνα με την ηλικία. Συγκεκριμένα, χρησιμοποιήθηκαν τα 60 μετρικά, με τη μεγαλύτερη συσχέτιση, όπου σε αυτά υπολογίστηκαν οι συσχετίσεις μεταξύ τους, με αποτέλεσμα να προκύψει ένας πίνακας με μέγεθος 60  $\times$  60. Επιπρόσθετα, υπολογίστηκε το άθροισμα των μέτρων των συσχετίσεων αυτού του πίνακα ανά γραμμή και στο τέλος από το διάνυσμα που εξήχθη, έγινε ταξινόμηση των στοιχείων του κατά αύξουσα σειρά.

Αλγόριθμος 5.9 - Εξαγωγή των μετρικών με τη μικρότερη συσχέτιση κατά αύξουσα σειρά
--

1. Αρχικοποίηση του πίνακα *correlation\_array*
2. Αρχικοποίηση του πίνακα *correlation\_vector*
3. Για κάθε *i* από 1 ως 60
4. Για κάθε *j* από 1 ως 60
5. Αν *i* ≠ *j*
6.  $r = \text{corrcoef}(\text{features}(1:94, i), \text{features}(1:94, j))$
7.  $\text{correlation\_array}(i, j) = \text{abs}(r)$
8. τέλος της συνθήκης
9. τέλος του δευτέρου βρόγχου
10. τέλος του πρώτου βρόγχου
11.  $\text{sum\_value} = 0$
12. Για κάθε *i* από 1 ως 60
13. Για κάθε *j* από 1 ως 60
14.  $\text{sum\_value} = \text{sum\_value} + \text{correlation\_array}(i, j)$
15. τέλος του δευτέρου βρόγχου
16.  $\text{correlation\_vector}(i) = \text{sum\_value}$
17. τέλος του πρώτου βρόγχου
18.  $\text{correlation\_vector} = \text{sort}(\text{correlation\_vector})$

Η συνάρτηση `corrcoef` υπολογίζει τη σταθερά συσχέτισης, ενώ η συνάρτηση `sort` ταξινομεί ένα διάνυσμα. Έτσι, με τη χρήση της παραπάνω μεθόδου γίνεται εκπαίδευση με τα πρώτα *k* μετρικά με το μικρότερο άθροισμα στα μέτρα των συσχετίσεων, για *k* από 1 ως 60. Για την κατάσταση των ανοιχτών ματιών επιλέγεται το *k* = 25, για την κατάσταση των κλειστών ματιών το *k* = 43, ενώ για τον συνδυασμό τους επιλέγεται και πάλι το *k* = 25.

### 5.5 Ομαδοποίηση των υποκειμένων

Η ομαδοποίηση των υποκειμένων γίνεται στις ηλικίες από 18 ως και 37 και από 38 ως και 60. Προκειμένου να γίνει αυτό, εκτιμάται αρχικά το κατά πόσο διαφέρουν στατιστικά ο πίνακας των μετρικών με την ηλικία, σύμφωνα με το κριτήριο t-test, από το οποίο προκύπτει ένα "σκορ" για κάθε μετρικό [27]. Έπειτα, η διαδικασία επαναλαμβάνεται 200 φορές, μεταθέτοντας τυχαία τις τιμές του πίνακα χαρακτηριστικών. Από τα "σκορ" που προκύπτουν υπολογίζεται ένα κατώφλι, το οποίο ισούται με:

$$\text{threshold} = \frac{\sum_{n=1}^{200} \text{scores}(n)}{200} + 2.5\text{std}(\text{scores}) \quad (5.19)$$

που *scores* είναι ο πίνακας των σκορ και `std` δηλώνει τη τυπική απόκλιση. Μετά χρησιμοποιήθηκαν στην εκπαίδευση τα χαρακτηριστικά με σκορ μεγαλύτερο ή ίσο από τη τιμή του κατωφλίου που υπολογίστηκε προηγουμένως. Σε αυτή την περίπτωση, ο ταξινομητής που χρησιμοποιήθηκε ήταν ο SVM.

## Αλγόριθμος 5.10 – Καθορισμός των μετρικών που χρησιμοποιήθηκαν στη κατηγοριοποίηση

1. Αρχικοποίηση του πίνακα *total\_scores*
2. Αρχικοποίηση του πίνακα *temp\_scores*
3.  $scores = \text{rankfeatures}(features, age)$
4. Για κάθε  $i$  από 1 ως 200
5.  $permuted\_index = \text{randpermute}(94)$
6.  $temp\_scores(i, 1: number\_of\_features) = \text{rankfeatures}(features(:, permuted\_index), age(permuted\_index))$
7. τέλος του βρόγχου
8.  $threshold = \text{mean}(temp\_scores) + 2.5 * \text{std}(temp\_scores)$   
 $features\_index\_values = (scores \geq threshold)$

## Κεφάλαιο 6: Αποτελέσματα

Στο κεφάλαιο αυτό παρουσιάζονται τα αποτελέσματα που εξήχθησαν από τη χρήση των χαρακτηριστικών για την πρόβλεψη της ηλικίας, τα οποία αναφέρθηκαν στο κεφάλαιο 5. Συγκεκριμένα, αναφέρονται οι σταθερές συσχέτισης των χαρακτηριστικών σε σχέση με την ηλικία, όπως και το ποια χαρακτηριστικά δίνουν τη μεγαλύτερη συσχέτιση. Επίσης, παρουσιάζονται τα γραφήματα της προβλεπόμενης ηλικίας σε σχέση με τη πραγματική, καθώς και οι τοπογραφικές απεικονίσεις των prototypes που προέκυψαν με τη χρήση του συνδυασμού NMF-VQ. Τέλος γίνεται ανάλυση του ποσοστού επιτυχίας από την ομαδοποίηση των υποκειμένων, ενώ εξάγονται και συμπεράσματα για τα αποτελέσματα που παρουσιάζονται.

### 6.1 Παρουσίαση αποτελεσμάτων στη πρόβλεψη της ηλικίας

Για κάθε ένα χαρακτηριστικό που περιγράφηκε στο κεφάλαιο 5, υπολογίστηκε η σταθερά συσχέτισης του με την ηλικία. Ο συνολικός αριθμός των μετρικών που χρησιμοποιήθηκαν ήταν 4282 για κάθε μία κατάσταση (μάτια ανοιχτά και μάτια κλειστά) και προκύπτει από το άθροισμα του μεγέθους του κάθε χαρακτηριστικού για κάθε υποκείμενο. Στον πίνακα 6.1 συνοψίζονται τα χαρακτηριστικά, καθώς και το μέγεθος του καθενός από αυτά που χρησιμοποιήθηκαν.

Όνομα χαρακτηριστικού	Μέγεθος
Ποσοστό μετάβασης στον πίνακα των συμβόλων από τον αλγόριθμο NMF-VQ	1
Ποσοστό μετάβασης στον πίνακα των συμβόλων από τον αλγόριθμο NMF-VQ ανά ζεύγος μικροκαταστάσεων	64
Δείκτης πολυπλοκότητας	20
Ποσοστό μετάβασης συχνοτήτων στους δυναμικούς γράφους ανά ζεύγος κόμβων	$64 \times 64 = 4096$
Ενδεικτική εντροπία	1
Ιστόγραμμα συχνοτήτων δυναμικών γράφων	36
Ποσοστό εντροπίας	64

**Πίνακας 6.1: Τα μεγέθη των χαρακτηριστικών που χρησιμοποιήθηκαν**

Όνομα χαρακτηριστικού	Σταθερά συσχέτισης
Ποσοστό μετάβασης στον πίνακα των συμβόλων από τον αλγόριθμο NMF-VQ	0.1540
Ποσοστό μετάβασης στον πίνακα των συμβόλων από τον αλγόριθμο NMF-VQ ανά ζεύγος μικρο-καταστάσεων	0.2281
Δείκτης πολυπλοκότητας	0.0414
Ποσοστό μετάβασης συχνοτήτων στους δυναμικούς γράφους ανά ζεύγος κόμβων	0.3610
Ενδεικτική εντροπία	0.0256
Ιστόγραμμα συχνοτήτων δυναμικών γράφων	0.3291
Ποσοστό εντροπίας	0.2204

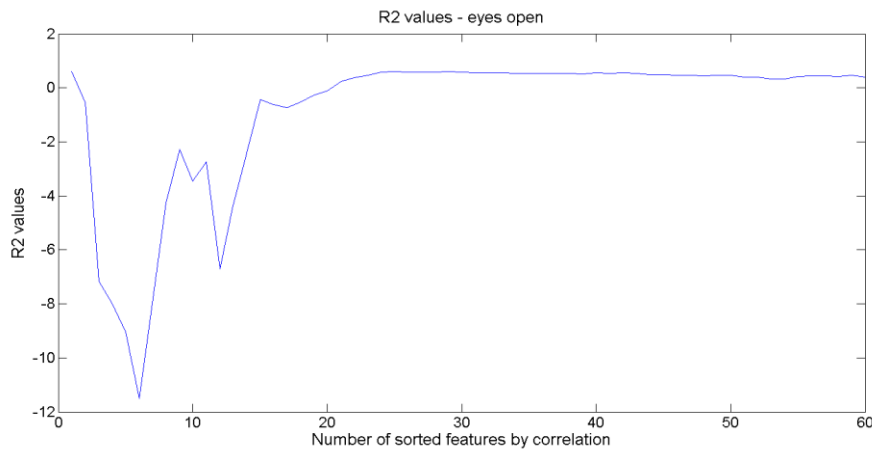
**Πίνακας 6.2: Μέγιστες τιμές των σταθερών συσχετίσεων για κάθε χαρακτηριστικό στην κατάσταση των ανοιχτών ματιών**

Όνομα χαρακτηριστικού	Σταθερά συσχέτισης
Ποσοστό μετάβασης στον πίνακα των συμβόλων από τον αλγόριθμο NMF-VQ	0.0329
Ποσοστό μετάβασης στον πίνακα των συμβόλων από τον αλγόριθμο NMF-VQ ανά ζεύγος μικρο-καταστάσεων	0.2059
Δείκτης πολυπλοκότητας	0.1275
Ποσοστό μετάβασης συχνοτήτων στους δυναμικούς γράφους ανά ζεύγος κόμβων	0.3816
Ενδεικτική εντροπία	0.2775
Ιστόγραμμα συχνοτήτων δυναμικών γράφων	0.2578
Ποσοστό εντροπίας	0.2775

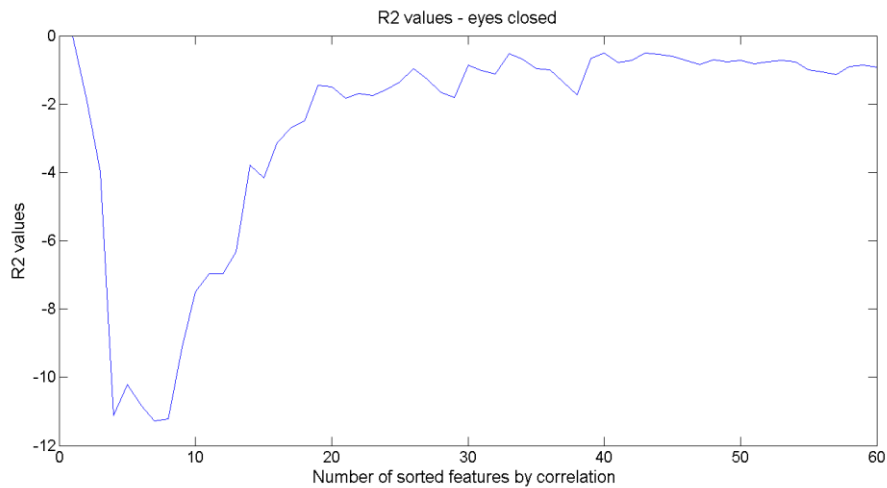
**Πίνακας 6.3: Μέγιστες τιμές των σταθερών συσχετίσεων για κάθε χαρακτηριστικό στην κατάσταση των κλειστών ματιών**

Έτσι, για κάθε ένα από τα 4282 μετρικά που χρησιμοποιήθηκαν, υπολογίστηκε η σταθερά συσχέτισης με την ηλικία. Στους πίνακες 6.2 και 6.2 φαίνονται οι μέγιστες τιμές των μέτρων των σταθερών συσχέτισης για τις δύο καταστάσεις. Οι εικόνες 6.1 και 6.2 δείχνουν τον αριθμό των χαρακτηριστικών που υπολογίστηκαν στον αλγόριθμο 5.8, για τον οποίο η τιμή του  $R^2$  συγκλίνει, για τις δύο καταστάσεις αντίστοιχα.





**Εικόνα 6.1: Τα χαρακτηριστικά με τη μεγαλύτερη συσχέτιση στην κατάσταση ανοιχτών ματιών**

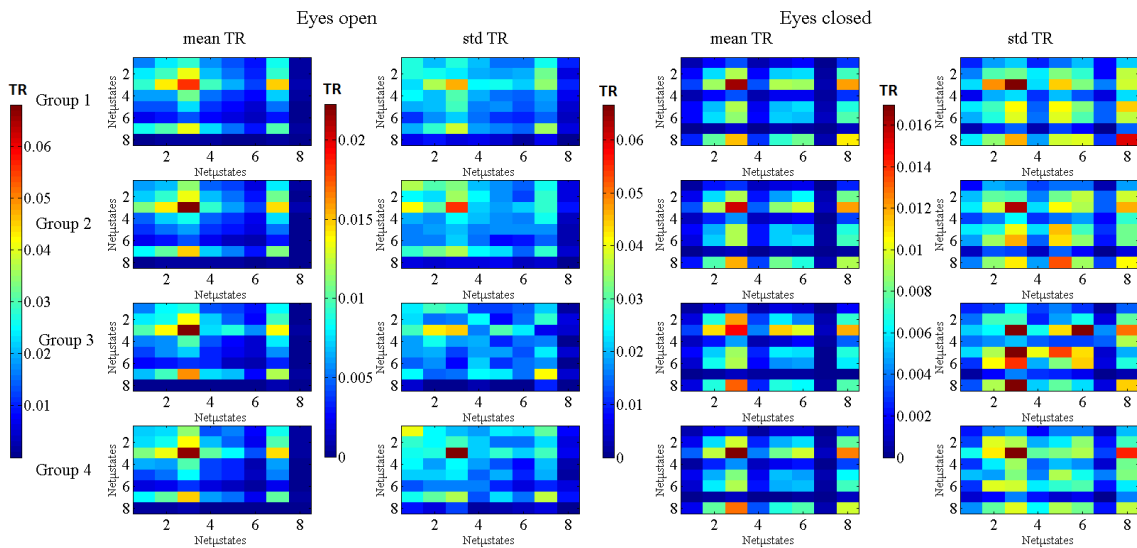


**Εικόνα 6.2: Τα χαρακτηριστικά με τη μεγαλύτερη συσχέτιση στην κατάσταση κλειστών ματιών**

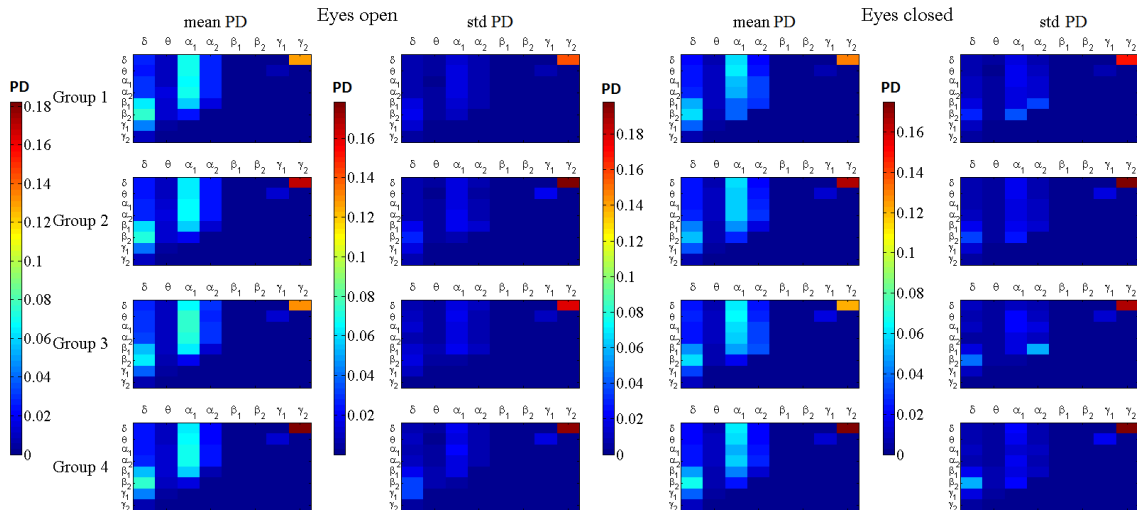
Τα συνολικά υποκείμενα χωρίστηκαν σε τέσσερις ηλικιακές ομάδες, οι οποίες φαίνονται παρακάτω:

- Group 1: Ηλικίες 18-27
- Group 2: Ηλικίες 28-37
- Group 3: Ηλικίες 38-40
- Group 4: Ηλικίες 50-60

Στην εικόνα 6.3 φαίνονται οι μέσες τιμές και οι τυπικές αποκλίσεις στα ποσοστά μεταβάσεων των κλάσεων του NMF-VQ, σε κάθε γκρουπ για τις καταστάσεις ανοιχτών και κλειστών ματιών. Ομοίως, στην εικόνα 6.4 παρουσιάζονται οι μέσες τιμές καθώς και οι τυπικές αποκλίσεις των κατανομών των συχνοτήτων στους δυναμικούς γράφους σε κάθε γκρουπ, για τις καταστάσεις των ανοιχτών και κλειστών ματιών.




**Εικόνα 6.3: Οι μέσες τιμές και οι τυπικές αποκλίσεις των μεταβάσεων στις κλάσεις του NMF-VQ, στις καταστάσεις ανοιχτών και κλειστών ματιών**




**Εικόνα 6.4: Οι μέσες τιμές και οι τυπικές αποκλίσεις των ιστογραμμάτων συχνοτήτων στους δυναμικούς γράφους στις καταστάσεις ανοιχτών και κλειστών ματιών**


Με βάση τις τιμές του  $R^2$  στις εικόνες 6.1 και 6.2 επιλέχθηκαν τα 25 πρώτα μετρικά με τη μικρότερη συσχέτιση μεταξύ τους στην κατάσταση των ανοιχτών ματιών και τα 43 πρώτα μετρικά με τη μικρότερη συσχέτιση μεταξύ τους στη κατάσταση των κλειστών ματιών αντίστοιχα. Έπειτα έγινε εκπαίδευση χρησιμοποιώντας τον ταξινομητή ELM εφαρμόζοντας τα μετρικά που επιλέχθηκαν προηγουμένως. Στις εικόνες 6.5, 6.6 και 6.7 φαίνονται οι προβλεπόμενες ηλικίες που εξήχθησαν σε συνάρτηση με τις πραγματικές ηλικίες, για τα μετρικά στις καταστάσεις ανοιχτών και κλειστών ματιών, καθώς και για τον συνδυασμό τους. Όσον αφορά τις τοπολογικές απεικονίσεις των prototypes, αυτές φαίνονται στις εικόνες 6.8 και 6.9 για τις καταστάσεις των ανοιχτών και κλειστών ματιών αντίστοιχα.



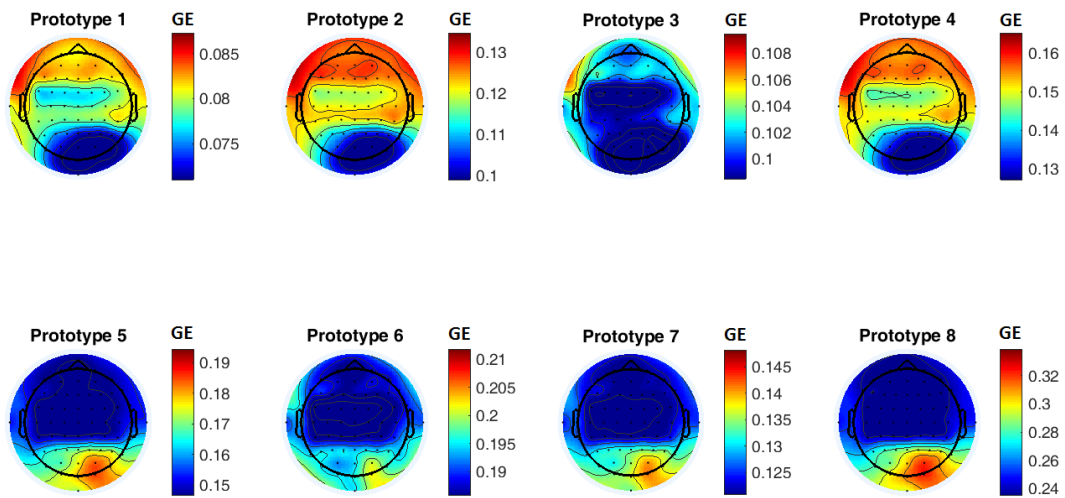
**Εικόνα 6.5:** Η προβλεπόμενη ηλικία σε σχέση με την πραγματική ηλικία με τη χρήση των μετρικών στην κατάσταση των ανοιχτών ματιών



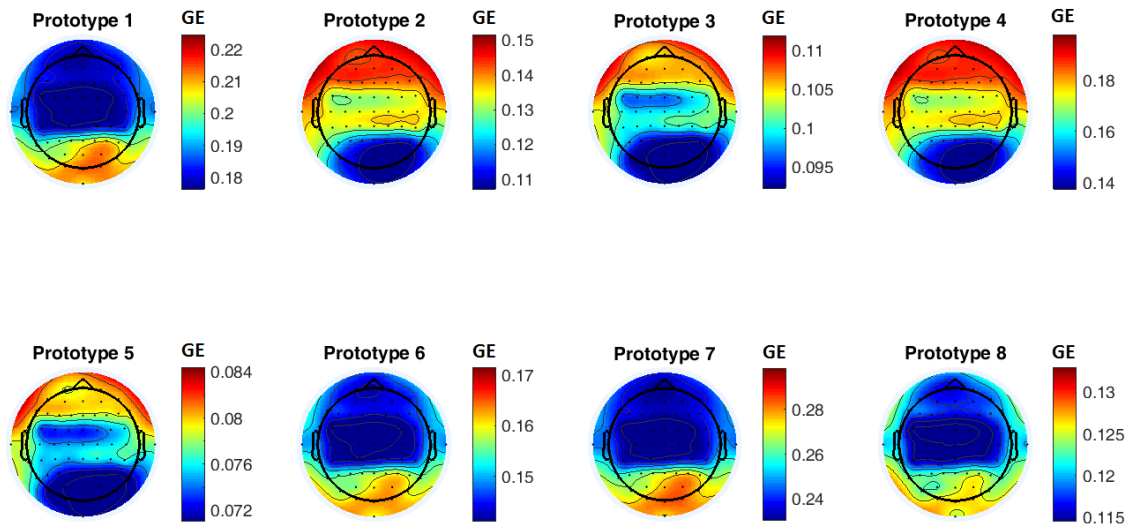
**Εικόνα 6.6:** Η προβλεπόμενη ηλικία σε σχέση με την πραγματική ηλικία με τη χρήση των μετρικών στην κατάσταση των κλειστών ματιών



**Εικόνα 6.7:** Η προβλεπόμενη ηλικία σε σχέση με την πραγματική ηλικία με τη χρήση των μετρικών στις καταστάσεις των ανοιχτών και κλειστών ματιών

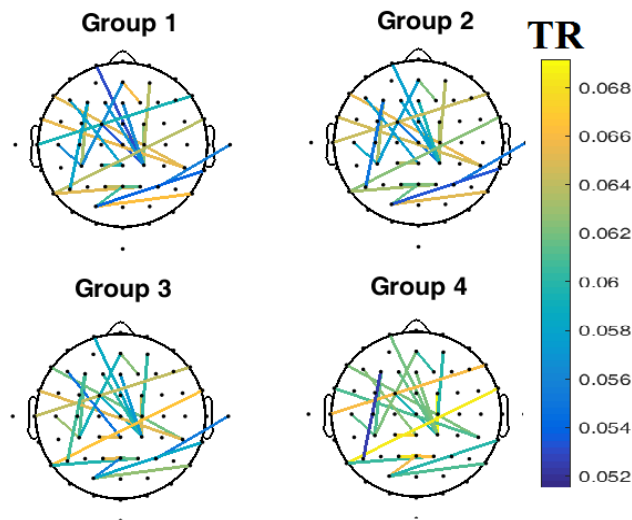


**Εικόνα 6.8: Τοπογραφικές απεικονίσεις των prototypes για την κατάσταση των ανοιχτών ματιών**

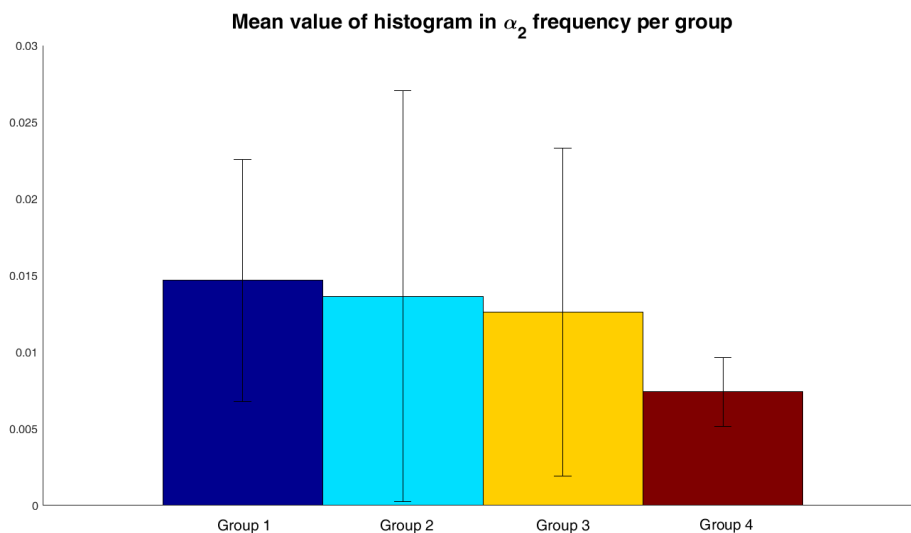


**Εικόνα 6.9: Τοπογραφικές απεικονίσεις των prototypes για την κατάσταση των κλειστών ματιών**

Στην εικόνα 6.10 φαίνονται οι τοπογραφικές απεικονίσεις των μέσων τιμών των ποσοστών μεταβάσεων συχνότητων ανά ζεύγος κόμβων για την κατάσταση των ανοιχτών ματιών σε κάθε γκρουπ, οι οποίες χρησιμοποιήθηκαν στην πρόβλεψη της ηλικίας. Οι συνολικές μεταβάσεις που χρησιμοποιήθηκαν ήταν 24. Επιπρόσθετα, στην εικόνα 6.11 φαίνονται οι μέσες τιμές του ιστογράμματος στη συχνότητα  $a_2$  για κάθε ηλικιακό γκρουπ. Το ιστόγραμμα στη συχνότητα  $a_2$  χρησιμοποιήθηκε και αυτό στη πρόβλεψη της ηλικίας.



**Εικόνα 6.10: Τοπογραφικές απεικονίσεις των μέσων τιμών των ποσοστών μεταβάσεων ανά ζεύγος κόμβων, οι οποίες χρησιμοποιήθηκαν στην πρόβλεψη της ηλικίας στην κατάσταση των ανοιχτών ματιών.**



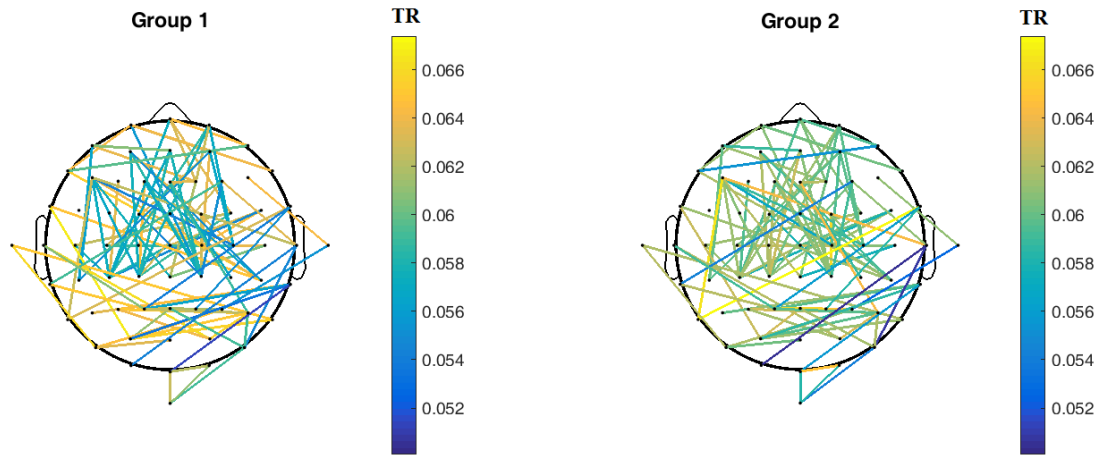
**Εικόνα 6.11: Μέσες τιμές του ιστογράμματος στη συχνότητα  $\alpha_2$  για κάθε ηλικιακή ομάδα.**

## 6.2 Παρουσίαση αποτελεσμάτων στην ομαδοποίηση των υποκειμένων στις ηλικιακές ομάδες

Στο υποκεφάλαιο αυτό παρουσιάζονται τα αποτελέσματα που εξήχθησαν από τα χαρακτηριστικά, τα οποία χρησιμοποιήθηκαν στην κατηγοριοποίηση των υποκειμένων. Όπως αναφέρθηκε στο κεφάλαιο 5, τα υποκείμενα χωρίστηκαν στις ηλικίες 18 ως και 37 και 38 ως και 60. Το ποσοστό επιτυχίας στην κατηγοριοποίηση των υποκειμένων ήταν ίσο με 97.8 %, για την κατάσταση των ανοιχτών ματιών, ενώ στην κατάσταση των κλειστών ματιών ήταν ίσο με 87.2 %.


Τα χαρακτηριστικά που επιλέχθηκαν σε αυτή την περίπτωση σύμφωνα με τη μέθοδο που περιγράφηκε στο κεφάλαιο 5.5 ήταν το ποσοστό μεταβάσεων ανά ζεύγος κόμβων (όπου χρησιμοποιήθηκαν 105

μετρικά από αυτό το χαρακτηριστικό), τα ιστογράμματα  $\alpha_1$  και  $\alpha_2$ , καθώς και το ποσοστό εντροπίας στις μαρκοβιανές αλυσίδες στις μεταβάσεις 4, 7 και 8, 5 για την κατάσταση των ανοιχτών ματιών. Η εικόνα 6.12 δείχνει τις μέσες τιμές των 105 μεταβάσεων ανά ζεύγος κόμβων που χρησιμοποιήθηκαν για την κατηγοριοποίηση της ηλικίας για κάθε ηλικιακή ομάδα.




**Εικόνα 6.12: Τοπογραφικές απεικονίσεις των μέσων τιμών των ποσοστών μεταβάσεων ανά ζεύγος κόμβων, που χρησιμοποιήθηκαν στην κατηγοριοποίηση των υποκειμένων στις δύο ηλικιακές ομάδες, για την κατάσταση των ανοιχτών ματιών**

Στις εικόνες 6.13 και 6.14 φαίνονται οι μέσες τιμές στα ιστογράμματα των συχνοτήτων  $\alpha_1$  και  $\alpha_2$  αντίστοιχα για κάθε ηλικιακή ομάδα.

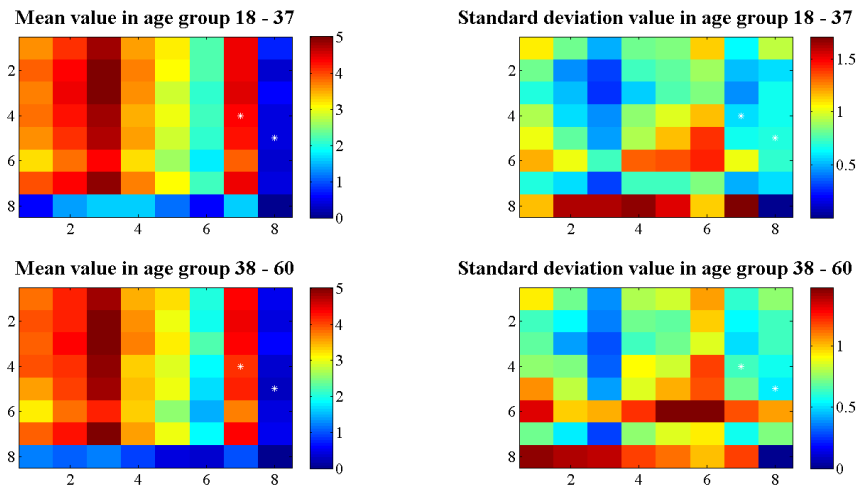


**Εικόνα 6.13: Μέσες τιμές του ιστογράμματος στη συχνότητα  $\alpha_1$  για κάθε ηλικιακή ομάδα.**



**Εικόνα 6.14: Μέσες τιμές του ιστογράμματος στη συχνότητα  $\alpha_2$  για κάθε ηλικιακή ομάδα.**

Η εικόνα 6.15 δείχνει τις μέσες τιμές και τις τυπικές αποκλίσεις των ποσοστών εντροπίας για τις δύο ηλικιακές ομάδες. Με αστερίσκο φαίνονται οι μεταβάσεις που χρησιμοποιήθηκαν στην ομαδοποίηση της ηλικίας από αυτό το χαρακτηριστικό.



**Εικόνα 6.15: Μέσες τιμές και τυπικές αποκλίσεις του ποσοστού εντροπίας για κάθε ηλικιακή ομάδα.**

### Συμπεράσματα

Στην παρούσα διατριβή εξετάστηκε μία νέα προσέγγιση στο πρόβλημα της πρόβλεψη της ηλικίας και της κατηγοριοποίησης των υποκειμένων σε ηλικιακές ομάδες. Η προσέγγιση αυτή περιελάμβανε τον υπολογισμό της λειτουργικής συνδεσιμότητας, χρησιμοποιώντας την προτεινόμενη μέθοδο NMF-VQ, καθώς και την επιλογή μιας πληθώρας χαρακτηριστικών τα οποία χρησιμοποιήθηκαν σαν είσοδο σε κατάλληλους ταξινομητές.

Τα αποτελέσματα που προέκυψαν από αυτή την ανάλυση ήταν αρκετά ικανοποιητικά, ειδικά με τη χρήση των σημάτων στην κατάσταση των ανοιχτών ματιών. Η πρόβλεψη της ηλικίας είχε τιμή  $R^2 = 0.6$ , ενώ το ποσοστό επιτυχίας στην κατηγοριοποίηση των υποκειμένων ήταν κοντά στο 97%. Αντίθετα, η χρήση των σημάτων στις καταστάσεις των κλειστών ματιών καθώς και στον συνδυασμό τους, δεν έδωσαν τόσο καλά αποτελέσματα στο πρόβλημα της πρόβλεψης της ηλικίας ( $R^2 = -0.48$  και  $R^2 = 0.31$  αντίστοιχα). Όσον αφορά την ομαδοποίηση των υποκειμένων, η χρήση των σημάτων EEG στην κατάσταση των κλειστών ματιών έδωσε ένα αξιόλογο ποσοστό επιτυχίας, το οποίο ήταν κοντά στο 85%.

Η χρήση των EEG σε κατάσταση ηρεμίας αποδεικνύει ότι αυτά τα σήματα περιέχουν επαρκή πληροφορία, προκειμένου να γίνει σωστά η πρόβλεψη της ηλικίας του υποκειμένου, καθώς και η κατηγοριοποίηση του σε ηλικιακές ομάδες. Όσο αυξάνεται η διαθεσιμότητα των συνόλων δεδομένων από σήματα EEG, νέες τεχνικές μπορούν να σχεδιαστούν και να εφαρμοστούν σε περισσότερα δεδομένα. Έτσι, πέρα από την πρόβλεψη της ηλικίας, η χρήση κατάλληλων χαρακτηριστικών και ταξινομητών μπορεί να οδηγήσει σε καλύτερες κλινικές διαγνώσεις, βελτιώνοντας τη συνολική αποδοτικότητά τους.



## Βιβλιογραφία

1. Saeid Sanei, J.A. Chambers, *EEG Signal Processing*, Cardiff: Wiley, 2007.
2. The McGill Physiology Virtual Lab, (2016). EEG. [online] Available at: [http://www.medicine.mcgill.ca/physio/vlab/biomed\\_signals/eeg\\_n.htm](http://www.medicine.mcgill.ca/physio/vlab/biomed_signals/eeg_n.htm)
3. Namburi, P. (2011). Phase Locking Value. [online] NeuroBytes. Available at: <https://praneethnamburi.wordpress.com/2011/08/10/plv>
4. Márton L.F., Bakó L., Brassai S.T., Losonczy L., “Multichannel EEG signal recording analysis based on Cross Frequency Coupling Method,” *Procedia Technology*, vol. 8, pp. 130-137, 2013.
5. Stavros I. Dimitriadis, Nikolaos A. Laskaris, Malamati P. Bitzidou, Ioannis Tarnanas, Magda N. Tsolaki, “A novel biomarker of amnesic MCI based on dynamic cross-frequency coupling patterns during cognitive brain responses,” *Frontiers in Neuroscience*, vol. 9, p. 350, 2015.
6. Juhan Aru, Jaan Aru, Viola Priesemann, Michael Wibral, Luiz Lana, Gordon Pipa, Wolf Singer, Raul Vicent, “Untagling cross-frequency coupling in neuroscience,” *Current Opinion in Neurobiology*, vol. 31, pp. 51-61, 2015.
7. Stavros I. Dimitriadis, Nicolaos A. Laskaris, Panagiotis G. Simos, Jack M. Fletcher, Andrew C. Papanicolaou, “Greater Repertoire and Temporal Variability of Cross-Frequency Coupling (CFC) Modes in Resting-State Neuromagnetic Recordings among Children with Reading Difficulties,” *Front. Hum. Neurosci.*, vol. 10, p. 163, 2016.
8. C. J. Stam, W. de Haan, A. Daffertshofer, B. F. Jones, I. Manshanden, A. M. van Cappellen van Walsum, T. Montez, J. P. A. Verbunt, J. C. de Munck, B. W. van Dijk, H. W. Berendse, P. Scheltens, “Graph Theoretical Analysis of magnetoencephalographic functional connectivity in Alzheimer’s disease,” *Brain*, vol. 132 (Pt 1), p.p. 213-224, 2009.
9. Ngoc diep-ho, “Non-negative matrix factorization algorithms and applications,” Ph.D. dissertation, Univ. Catholique de Louvain, Louvain, Belgium, 2008.
10. Daniel D. Lee, H. Sebastian Seung, “Algorithms on Non-negative matrix factorization,” *Neural Information Processing Systems*, p.p. 556-562, Denver, Colorado, 2000.
11. Telesford QK, Simpson SL, Burdette JH, Hayasaka S, Laurienti PJ, “The Brain as a Complex System: Using Network Science as a Tool for Understanding the Brain,” *Brain Connect.*, vol. 1.4, p.p. 295-308, 2011.
12. Nedrich, M. (2014). An Introduction to Gradient Descent and Linear Regression. [online] Atomic Spin. Available at : <https://spin.atomicobject.com/2014/06/24/gradient-descent-linear-regression/>
13. Ke-Lin Du, M. N. S. Swamy, *Neural Networks and Statistical Learning*, London: Springer, 2014.
14. Van Wijk BC., Stam CJ, Daffertshofer A., “Comparing Brain Networks of Different Size and Connectivity Density Using Graph Theory,” *PLoS ONE*, vol. 5, p. 10, 2010.
15. KOWALCZYK, A. SVM - Understanding the math - Part 1 - The margin - SVM Tutorial. [online] SVM Tutorial. Available at: <http://www.svm-tutorial.com/2014/11/svm-understanding-math-part-1/>
16. John Nachbar, “Finite Dimensional Optimization Part I, The Karush-Kuhn-Tucker Theorem,” Univ. Washington, 2016.
17. Deshpande, B. (2016). How support vector machines use kernel functions to classify data. [online] Simafore.com. Available at: <http://www.simafore.com/blog/bid/113227/How-to-support-vector-machines-use-kernel-functions-to-classify-data>
18. Carlos Gershenson, *Artificial Neural Networks for Beginners*, Cornell University Library, New York, 2003.
19. UFDL Tutorial (2016). Unsupervised Feature Learning and Deep Learning Tutorial. [online] Available at: <http://ufldl.stanford.edu/tutorial/supervised/MultiLayerNeuralNetworks/>
20. Shifei Ding, Han Zhao, Yanan Zhang, Xinzheng Xu, Ru Nie, “Extreme learning machine: algorithm, theory and applications,” *Artificial Intelligence Review*, vol. 44, p.p. 103-115, 2013.
21. Barata J., Hussein M., “The Moore–Penrose Pseudoinverse: A Tutorial Review of the Theory,” *Brazilian Journal of Physics*, vol. 42, p.p. 146-165, 2011.
22. “EEG Motor Movement/Imagery Dataset”, Physionet.org, 2016. [online]. Available: <https://www.physionet.org/pn4/eegmidb/>.
23. Stavros I. Dimitriadis, Nikolaos A. Laskaris, Vasso Tsirka, Sofia Erimaki, Michael Vourkas, Sifis Micheloyannis, Spiros Fotopoulos, “A novel symbolization scheme for multichannel recordings with

- emphasis on phase information and its application to differentiate EEG activity from different mental tasks,” *Cognitive Neurodynamics*, vol. 6, p.p. 107-113, 2011.
24. Svante Janson, Stefano Lonardi, Wojciech Szpankowski, “On average sequence complexity,” *Theoretical Computer Science*, vol. 326, p.p. 213-227, 2004.
  25. G. Moody, Approximate Entropy (ApEn), Physionet.org, 2016. [Online]. Available: <https://www.physionet.org/physiotools/ApEn/>
  26. Madalena Costa, Ary L. Goldberger, C.-K. Peng, “Multiscale entropy analysis of biological signals,” *Physical Review E*, vol. 71, 2005.
  27. Laura Ekroot, Thomas M. Cover, “The entropy of Markov trajectories,” *IEEE Transactions on Information Theory*, vol. 39, p.p. 1418-1421, 1993.
  28. Theodoridis S., Koutroumbas K., *Pattern recognition*, Amsterdam: Elsevier/Academic Press, 2006.
  29. Jean-Philippe Lachaux, Eugenio Rodriguez, Jacques Martinerie, Francisco J. Varela, “Measuring Phase Synchrony in Brain Signals,” *Human Brain Mapping*, vol. 8, p.p. 194-208, 1999.
  30. Dosenbach NU, *et al.*, “Prediction of Individual Brain Maturity Using fMRI,” *Science*, vol. 329, p.p. 1358-1361, 2010.
  31. Vergun S., *et al.*, “Characterizing Functional Connectivity Differences in Aging Adults using Machine Learning on Resting State fMRI Data,” *Front. Comput. Neurosci.*, vol. 7, p. 38, 2013.