



**ΠΑΝΕΠΙΣΤΗΜΙΟ ΙΩΑΝΝΙΝΩΝ  
ΣΧΟΛΗ ΕΠΙΣΤΗΜΩΝ ΥΓΕΙΑΣ  
ΤΜΗΜΑ ΙΑΤΡΙΚΗΣ**

**ΛΕΙΤΟΥΡΓΙΚΟΣ - ΚΛΙΝΙΚΟΕΡΓΑΣΤΗΡΙΑΚΟΣ ΤΟΜΕΑΣ  
ΕΡΓΑΣΤΗΡΙΟ ΦΥΣΙΟΛΟΓΙΑΣ**

**«Ψηφιακή Ανάλυση Ηλεκτροεγκεφαλογραφικού Σήματος  
(ΗΕΓ) Εφαρμογές στην Εκπαίδευση»**

**Στεφανίδης Κ. Βασίλειος**  
Πληροφορικός

**ΔΙΔΑΚΤΟΡΙΚΗ ΔΙΑΤΡΙΒΗ**

**ΙΩΑΝΝΙΝΑ 2017**











**ΠΑΝΕΠΙΣΤΗΜΙΟ ΙΩΑΝΝΙΝΩΝ  
ΣΧΟΛΗ ΕΠΙΣΤΗΜΩΝ ΥΓΕΙΑΣ  
ΤΜΗΜΑ ΙΑΤΡΙΚΗΣ**

**ΛΕΙΤΟΥΡΓΙΚΟΣ - ΚΛΙΝΙΚΟΕΡΓΑΣΤΗΡΙΑΚΟΣ ΤΟΜΕΑΣ  
ΕΡΓΑΣΤΗΡΙΟ ΦΥΣΙΟΛΟΓΙΑΣ**

**«Ψηφιακή Ανάλυση Ηλεκτροεγκεφαλογραφικού Σήματος  
(ΗΕΓ) Εφαρμογές στην Εκπαίδευση»**

**Στεφανίδης Κ. Βασίλειος**  
Πληροφορικός

**ΔΙΔΑΚΤΟΡΙΚΗ ΔΙΑΤΡΙΒΗ**

**ΙΩΑΝΝΙΝΑ 2017**



«Η έγκριση της διδακτορικής διατριβής από το Τμήμα Ιατρικής του Πανεπιστημίου Ιωαννίνων δεν υποδηλώνει αποδοχή των γνώμων του συγγραφέα Ν. 5343/32, άρθρο 202, παράγραφος 2 (νομική κατοχύρωση του Ιατρικού Τμήματος)».



**Ημερομηνία αίτησης του κ. Στεφανίδη Βασιλείου : 20-1-2014**

**Ημερομηνία ορισμού Τριμελούς Συμβουλευτικής Επιτροπής: 759<sup>α</sup>/14-2-2014**

**Μέλη Τριμελούς Συμβουλευτικής Επιτροπής:**

Επιβλέπων

Ευαγγέλου Άγγελος, Καθηγητής Φυσιολογίας

Μέλη

Ανωγειανάκης Γεώργιος Καθηγητή Φυσιολογίας, Πανεπιστήμιο ΑΠΘ

Πούλος Μάριος Επίκουρος Καθηγητής Τμήματος Αρχειονομίας-Βιβλιοθηκονομίας και Μουσειολογίας του Ιονίου Πανεπιστημίου

**Ημερομηνία ορισμού θέματος: 2-4-2014**

*«Ψηφιακή ανάλυση Ηλεκτροεγκεφαλογραφικού σήματος (ΗΕΓ)-Εφαρμογές στην Εκπαίδευση»*

**ΟΡΙΣΜΟΣ ΕΠΤΑΜΕΛΟΥΣ ΕΞΕΤΑΣΤΙΚΗΣ ΕΠΙΤΡΟΠΗΣ : 796<sup>α</sup>/29-3-2017**

1. Ευαγγέλου Άγγελος Ομότιμος Καθηγητής Φυσιολογίας του Τμήματος Ιατρικής του Παν/μίου Ιωαννίνων
2. Ανωγειανάκης Γεώργιος τ. Καθηγητής Φυσιολογίας, του Τμήματος Ιατρικής του Πανεπιστημίου ΑΠΘ
3. Βλάμος Παναγιώτης Καθηγητής Τμήματος Πληροφορικής του Ιονίου Πανεπιστημίου
4. Καλφακάκου Βασιλική Καθηγήτρια Φυσιολογίας με έμφαση στην Περιβαλλοντική Φυσιολογία του Τμήματος Ιατρικής του Παν/μίου Ιωαννίνων
5. Κουτσονικόλας Δημήτριος Αναπληρωτής Καθηγητής Φυσιολογίας του Τμήματος Ιατρικής του Πανεπιστημίου ΑΠΘ
6. Πέσχος Δημήτριος Αναπληρωτής Καθηγητής Φυσιολογίας με έμφαση στην Κυτταρική Φυσιολογία του Τμήματος Ιατρικής του Παν/μίου Ιωαννίνων
7. Πούλος Μάριος Αναπληρωτής Καθηγητής Τμήματος Αρχειονομίας-Βιβλιοθηκονομίας και Μουσειολογίας του Ιονίου Πανεπιστημίου

Έγκριση Διδακτορικής Διατριβής με βαθμό «ΑΡΙΣΤΑ» στις 3-5-2017

**ΠΡΟΕΔΡΟΣ ΤΟΥ ΤΜΗΜΑΤΟΣ ΙΑΤΡΙΚΗΣ**

**Πασχόπουλος Μηνάς**

Καθηγητής Μαιευτικής-Γυναικολογίας





## Ευχαριστίες

Θα ήθελα να ευχαριστήσω τον επιβλέποντα, Καθηγητή Φυσιολογίας του Πανεπιστημίου Ιωαννίνων, κ. Άγγελο Ευαγγέλου για την ευκαιρία που μου έδωσε να ενασχοληθώ ερευνητικά με το πρωτότυπο ζήτημα επίλυσης μαθησιακών δυσκολιών του εγκεφάλου καθώς και τα μέλη της τριμελούς επιτροπής, κ. Γεώργιο Ανωγειανάκι, Καθηγητή Φυσιολογίας του Αριστοτελείου Πανεπιστημίου Θεσσαλονίκης και κ. Μάριο Πούλο, Αναπληρωτή Καθηγητή Σηματολογικής Επεξεργασίας της Πληροφορίας του Τμήματος Αρχειονομίας και Βιβλιοθηκονομίας του Ιονίου Πανεπιστημίου, για τη σημαντική βοήθειά τους σε όλη τη διάρκεια της εκπόνησης της διδακτορικής μου διατριβής. Αισθάνομαι ιδιαίτερα τυχερός άνθρωπος που τους γνώρισα και συνεργάστηκα μαζί τους.





*το αφιερώνω*

*στην οικογένειά μου,  
στη γυναίκα μου Νάνσυ,  
και στα παιδιά μου Τζίνα και Κυριάκο*

*και στους γονείς μου  
Κυριάκο και Γεωργία*



# Εικόνες

|                                                                                                                                                                                                                                                                                                                      |     |
|----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| <i>Εικόνα 1: Ο Ανθρώπινος Εγκέφαλος</i> .....                                                                                                                                                                                                                                                                        | 29  |
| <i>Εικόνα 2: Ανθρώπινο Εγκεφαλικό Νεύρο ή Νευρώνας</i> .....                                                                                                                                                                                                                                                         | 49  |
| <i>Εικόνα 3: Απολείξεις, Δενδρίτες και Συνάψεις</i> .....                                                                                                                                                                                                                                                            | 50  |
| <i>Εικόνα 4: Δυναμικό Δράσης – Πόλωση Εκπόλωση Νευρικού Κυτάρρου</i> .....                                                                                                                                                                                                                                           | 51  |
| <i>Εικόνα 5: Το Διεθνές Σύστημα 10-20</i> .....                                                                                                                                                                                                                                                                      | 55  |
| <i>Εικόνα 6: Διάφορα μοντάζ</i> .....                                                                                                                                                                                                                                                                                | 57  |
| <i>Εικόνα 7: Ηλεκτροεγκεφαλογράφημα με Εγκεφαλικούς Ρυθμούς</i> .....                                                                                                                                                                                                                                                | 59  |
| <i>Εικόνα 8: Ρυθμός Άλφα - Άδεια δημοσίευσης GNU/GPL - Brainwave images © Hugo Gamboa Dez 2005</i><br>( <a href="https://commons.wikimedia.org/wiki/File:Eeg_alpha.svg">https://commons.wikimedia.org/wiki/File:Eeg_alpha.svg</a> ) .....                                                                            | 60  |
| <i>Εικόνα 9: Ρυθμός Βήτα - Άδεια δημοσίευσης GNU/GPL - Brainwave images © Hugo Gamboa Dez 2005</i><br>( <a href="https://commons.wikimedia.org/wiki/File:Eeg_beta.svg">https://commons.wikimedia.org/wiki/File:Eeg_beta.svg</a> ) .....                                                                              | 60  |
| <i>Εικόνα 10: Ρυθμός Θήτα - Άδεια δημοσίευσης GNU/GPL - Brainwave images © Hugo Gamboa Dez 2005</i><br>( <a href="https://commons.wikimedia.org/wiki/File:Eeg_theta.svg">https://commons.wikimedia.org/wiki/File:Eeg_theta.svg</a> ) .....                                                                           | 61  |
| <i>Εικόνα 11: Ρυθμός Δέλτα - Άδεια δημοσίευσης GNU/GPL - Brainwave images © Hugo Gamboa Dez 2005</i><br>( <a href="https://commons.wikimedia.org/wiki/File:Eeg_delta.svg">https://commons.wikimedia.org/wiki/File:Eeg_delta.svg</a> ) .....                                                                          | 61  |
| <i>Εικόνα 12: Ρυθμός Γάμα - Άδεια δημοσίευσης GNU/GPL - Brainwave images © Hugo Gamboa Dez 2005</i><br>( <a href="https://commons.wikimedia.org/wiki/File:Eeg_gamma.svg">https://commons.wikimedia.org/wiki/File:Eeg_gamma.svg</a> ) .....                                                                           | 62  |
| <i>Εικόνα 13: Συνεχές-Αναλογικό Σήμα</i> .....                                                                                                                                                                                                                                                                       | 65  |
| <i>Εικόνα 14: Διακριτό-Ψηφιακό Σήμα</i> .....                                                                                                                                                                                                                                                                        | 66  |
| <i>Εικόνα 15: Σήματα Διακριτού Χρόνου με Ανάλυση Fourier DTF</i> .....                                                                                                                                                                                                                                               | 68  |
| <i>Εικόνα 16: Ανάλυση Fast Fourier FFT</i> .....                                                                                                                                                                                                                                                                     | 69  |
| <i>Εικόνα 17: Γραμμική συνάρτηση κατωφλίου που χρησιμοποιείται ως συνάρτηση μεταφοράς για τους ανιχνευτές χαρακτηριστικών και τους ανιχνευτές προτύπων. Η αύξηση της δραστηριοποίησης από κάποιο σημείο και μετά είναι γραμμική (Α). Μία εναλλακτική συνάρτηση μεταφοράς για τους ανιχνευτές προτύπων (Β).</i> ..... | 78  |
| <i>Εικόνα 18: Μη γραμμική συνάρτηση κατωφλίου που χρησιμοποιείται ως συνάρτηση μεταφοράς για τους ανιχνευτές χαρακτηριστικών και τους ανιχνευτές προτύπων (σιγμοειδής συνάρτηση).</i> .....                                                                                                                          | 80  |
| <i>Εικόνα 19: Ο δείκτης GFP για το κανάλι 10 ενός ατόμου. Με κόκκινο η καταγραφή του ατόμου που εκτελεί τη δύσκολη εκπαιδευτική διαδικασία και με μπλε η καταγραφή του ατόμου που εκτελεί την εύκολη εκπαιδευτική διαδικασία</i> .....                                                                               | 106 |
| <i>Εικόνα 20: Διάγραμμα ERP με κορυφώσεις Αρνητικές (N - Negative) και Θετικές (P - Positive)</i> .....                                                                                                                                                                                                              | 107 |
| <i>Εικόνα 21: Διάγραμμα ERP των 28 καναλιών</i> .....                                                                                                                                                                                                                                                                | 113 |
| <i>Εικόνα 22: Υπολογισμός δεικτών ERSP και ITC ενός subject κατά τη διαδικασία αναγνώρισης «εύκολης εικόνας»</i> .....                                                                                                                                                                                               | 114 |

|                                                                                                                                                                                       |            |
|---------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------|
| <i>Εικόνα 23: Υπολογισμός δείκτη Power Spectral κατά τη διαδικασία αναγνώρισης «δύσκολης εικόνας» .....</i>                                                                           | <i>115</i> |
| <i>Εικόνα 24: Μια non-target εικόνα .....</i>                                                                                                                                         | <i>123</i> |
| <i>Εικόνα 25: Μια target easy (εύκολη) εικόνα .....</i>                                                                                                                               | <i>123</i> |
| <i>Εικόνα 26: Μια target hard (δύσκολη) εικόνα .....</i>                                                                                                                              | <i>124</i> |
| <i>Εικόνα 27: Σχηματική αναπαράσταση της ερευνητικής διαδικασίας .....</i>                                                                                                            | <i>125</i> |
| <i>Εικόνα 28: Περιγραφή πειραματικής διαδικασίας για μια απάντηση .....</i>                                                                                                           | <i>126</i> |
| <i>Εικόνα 29: Ελαστικό καπέλο με τα 32 ηλεκτρόδια .....</i>                                                                                                                           | <i>126</i> |
| <i>Εικόνα 30: Τοπολογία ηλεκτροδίων με το μαστοειδές ως αναφορά.....</i>                                                                                                              | <i>127</i> |
| <i>Εικόνα 31: Η Χωρική Διάταξη των 32 Ηλεκτροδίων [147] .....</i>                                                                                                                     | <i>127</i> |
| <i>Εικόνα 32: Αρχείο loc με τις ακριβείς θέσεις και ονομασίες των ηλεκτροδίων ..</i>                                                                                                  | <i>128</i> |
| <i>Εικόνα 33: Λογισμικό EEGLab .....</i>                                                                                                                                              | <i>129</i> |
| <i>Εικόνα 34: Περιγραφή χρονικού διαστήματος pre και post stimulus .....</i>                                                                                                          | <i>131</i> |
| <i>Εικόνα 35: Η πρώτη οθόνη του λογισμικού WEKA .....</i>                                                                                                                             | <i>132</i> |
| <i>Εικόνα 36: Κύρια διεπαφή του Weka Explorer, με τα δεδομένα καταχωρισμένα με βάση 3 κλάσεις .....</i>                                                                               | <i>134</i> |
| <i>Εικόνα 37: Κάνοντας την επιλογή “Visualize all” .....</i>                                                                                                                          | <i>135</i> |
| <i>Εικόνα 38: Αποτέλεσμα Ταξινόμησης .....</i>                                                                                                                                        | <i>136</i> |
| <i>Εικόνα 39: Συντελεστές του Πολυωνύμου παρεμβολής .....</i>                                                                                                                         | <i>142</i> |
| <i>Εικόνα 40: Γραφική αναπαράσταση του Πολυωνύμου n-οστού βαθμού evaluated at x (eq. 9) .....</i>                                                                                     | <i>143</i> |
| <i>Εικόνα 41: Αναπαράσταση πολυωνύμου (eq. 9) για μια γυναίκα (αριστερά) και έναν άνδρα (δεξιά) .....</i>                                                                             | <i>144</i> |
| <i>Εικόνα 42: Πολυωνυμική αναπαράσταση σταθερών σημείων ενός άνδρα (<math>k = 10, w = 20</math>) .....</i>                                                                            | <i>145</i> |
| <i>Εικόνα 43: Πολυωνυμική αναπαράσταση σταθερών σημείων μιας γυναίκας ...</i>                                                                                                         | <i>146</i> |
| <i>Εικόνα 44: Πρότυπο Στάσιμου Κύματος με τις χαρακτηριστικές ατράκτους ....</i>                                                                                                      | <i>146</i> |
| <i>Εικόνα 45: Στάσιμα κύματα σε 6 EEGs ανά άτομο (5 άτομα) .....</i>                                                                                                                  | <i>146</i> |
| <i>Εικόνα 46: Απεικόνιση σταθερών σημείων κατά τη διαδικασία εύρεσης τομών από regression έξι πολυωνύμων μέσω του αλγορίθμου ACC για μικρό σετ δεδομένων (<math>k=6</math>) .....</i> | <i>151</i> |
| <i>Εικόνα 47: Καμπύλη του μοτίβου A .....</i>                                                                                                                                         | <i>151</i> |
| <i>Εικόνα 48: Καμπύλη του μοτίβου B .....</i>                                                                                                                                         | <i>152</i> |
| <i>Εικόνα 49: Απεικόνιση σταθερών σημείων με τη χρήση 50 τεμνόμενων καμπυλών.....</i>                                                                                                 | <i>152</i> |
| <i>Εικόνα 50: Τα αποτελέσματα ομαδοποίησης των τεμνόμενων καμπυλών της Εικόνα 49.....</i>                                                                                             | <i>153</i> |
| <i>Εικόνα 51: Ικανότητα ορθής πρόβλεψης ταξινομητών για δεδομένα με δείκτη GFP.....</i>                                                                                               | <i>159</i> |
| <i>Εικόνα 52: Μέσο τετραγωνικό σφάλμα ταξινομητών για δεδομένα με δείκτη GFP .....</i>                                                                                                | <i>159</i> |
| <i>Εικόνα 53: Χρόνος δημιουργίας μοντέλου για δεδομένα με δείκτη GFP .....</i>                                                                                                        | <i>160</i> |
| <i>Εικόνα 54: Stratified cross-validation classification summary.....</i>                                                                                                             | <i>160</i> |
| <i>Εικόνα 55: Ικανότητα ορθής πρόβλεψης ταξινομητών για δεδομένα με δείκτη Power Spectral.....</i>                                                                                    | <i>163</i> |
| <i>Εικόνα 56: Μέσο τετραγωνικό σφάλμα ταξινομητών για δεδομένα με δείκτη Power Spectral.....</i>                                                                                      | <i>163</i> |
| <i>Εικόνα 57: Χρόνος δημιουργίας μοντέλου για δεδομένα με δείκτη Power Spectral</i>                                                                                                   | <i>164</i> |

|                                                                                                                                                                                         |            |
|-----------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------|
| <i>Εικόνα 58: Ικανότητα ορθής πρόβλεψης ταξινομητών για δεδομένα με δείκτη ERSP.....</i>                                                                                                | <i>167</i> |
| <i>Εικόνα 59: Μέσο τετραγωνικό σφάλμα ταξινομητών για δεδομένα με δείκτη ERSP.....</i>                                                                                                  | <i>167</i> |
| <i>Εικόνα 60: Χρόνος δημιουργίας μοντέλου για δεδομένα με δείκτη ERSP .....</i>                                                                                                         | <i>168</i> |
| <i>Εικόνα 61: Αποτελέσματα σωστής ταξινόμησης όλων των δεικτών ανά αλγόριθμο .....</i>                                                                                                  | <i>170</i> |
| <i>Εικόνα 62: Αποτελέσματα λανθασμένης ταξινόμησης όλων των δεικτών ανά αλγόριθμο .....</i>                                                                                             | <i>171</i> |
| <i>Εικόνα 63: Αποτελέσματα επί τις εκατό σωστής ταξινόμησης όλων των δεικτών ανά αλγόριθμο .....</i>                                                                                    | <i>171</i> |
| <i>Εικόνα 64: Εύκολες εικόνες που ταξινομήθηκαν ως εύκολες για τους τρεις δείκτες.....</i>                                                                                              | <i>174</i> |
| <i>Εικόνα 65: Δύσκολες εικόνες που ταξινομήθηκαν ως μη εύκολες για τους τρεις δείκτες.....</i>                                                                                          | <i>174</i> |
| <i>Εικόνα 66: Δείκτης Sencitivity για τους τρεις δείκτες.....</i>                                                                                                                       | <i>175</i> |
| <i>Εικόνα 67: Δείκτης Specificity για τους τρεις δείκτες .....</i>                                                                                                                      | <i>175</i> |
| <i>Εικόνα 68: Οθόνη του WEKA με την εφαρμογή του αλγόριθμου βελτιστοποίησης απόδοσης ConsistencySubsetEval, επάνω στον δείκτη GFP .....</i>                                             | <i>180</i> |
| <i>Εικόνα 69: Οπτικοποίηση σωστής ταξινόμησης του δείκτη GFP ανά αλγόριθμο, μετά τη βελτιστοποίηση με τον τον αλγόριθμο ConsistencySubsetEval .....</i>                                 | <i>181</i> |
| <i>Εικόνα 70: Διαγραμματική οπτικοποίηση της βελτιωμένης ταξινόμησης ως προς τον δείκτη GFP, μετά τη βελτιστοποίηση με τον τον αλγόριθμο ConsistencySubsetEval .....</i>                | <i>181</i> |
| <i>Εικόνα 71: Λοβοί του ανθρώπινου εγκεφάλου.....</i>                                                                                                                                   | <i>183</i> |
| <i>Εικόνα 72: GFP διαγράμματα για Μετωπιαία (Frontal) Ηλεκτρόδια 1 και 2.....</i>                                                                                                       | <i>183</i> |
| <i>Εικόνα 73: GFP διαγράμματα για Πλευρικά (Parietal) Ηλεκτρόδια 7 και 8.....</i>                                                                                                       | <i>184</i> |
| <i>Εικόνα 74: GFP διαγράμματα για Ινιακά (Occipital) Ηλεκτρόδια 9 και 10 .....</i>                                                                                                      | <i>184</i> |
| <i>Εικόνα 75: GFP διαγράμματα για Κροταφικά (Temporal) Ηλεκτρόδια 13 και 16 .....</i>                                                                                                   | <i>184</i> |
| <i>Εικόνα 76: GFP διαγράμματα για τα Ηλεκτρόδια 11 και 12 όπου φαίνονται οι κορυφώσεις P200, P300, N250, N400.....</i>                                                                  | <i>185</i> |
| <i>Εικόνα 77: Οπτικοποίηση ηλεκτρικής δραστηριότητας εγκεφάλου που υπόκειται σε μια εύκολη εκπαιδευτική διαδικασία (η χρωματιστή κλίμακα είναι ηλεκτρική δραστηριότητα σε mV).....</i>  | <i>186</i> |
| <i>Εικόνα 78: Οπτικοποίηση ηλεκτρικής δραστηριότητας εγκεφάλου που υπόκειται σε μια δύσκολη εκπαιδευτική διαδικασία (η χρωματιστή κλίμακα είναι ηλεκτρική δραστηριότητα σε mV).....</i> | <i>188</i> |
| <i>Εικόνα 79: Οπτικοποίηση ηλεκτρικής δραστηριότητας εγκεφάλου που υπόκειται σε μια δύσκολη (αριστερά) και μια εύκολη (δεξιά) εκπαιδευτική διαδικασία 300ms μετά το ερέθισμα .....</i>  | <i>189</i> |
| <i>Εικόνα 80: Ικανότητα ορθής πρόβλεψης ταξινομητών για δεδομένα με δείκτη GFP μετά την αφαίρεση της επίδρασης των προκλητών δυναμικών .....</i>                                        | <i>192</i> |
| <i>Εικόνα 81: Μέσο τετραγωνικό σφάλμα ταξινομητών για δεδομένα με δείκτη GFP μετά την αφαίρεση της επίδρασης των προκλητών δυναμικών .....</i>                                          | <i>193</i> |
| <i>Εικόνα 82: Χρόνος δημιουργίας μοντέλου για δεδομένα με δείκτη GFP μετά την αφαίρεση της επίδρασης των προκλητών δυναμικών .....</i>                                                  | <i>193</i> |

|                                                                                                                                                                                                                                                                  |            |
|------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------------|------------|
| <i>Εικόνα 83: Stratified cross-validation classification summary μετά τη αφαίρεση της επίδρασης των προκλητών δυναμικών .....</i>                                                                                                                                | <i>194</i> |
| <i>Εικόνα 84: Διαγραμματική οπτικοποίηση της βελτιωμένης ταξινόμησης ως προς τον δείκτη GFP, πριν και μετά την αφαίρεση των προκλητών δυναμικών .....</i>                                                                                                        | <i>196</i> |
| <i>Εικόνα 85: Συγκριτική διαγραμματική οπτικοποίηση της βελτιωμένης ταξινόμησης ως προς τον δείκτη GFP, πριν την αφαίρεση των προκλητών δυναμικών, μετά την εφαρμογή του αλγόριθμου ConsistencySubsetEval και μετά την αφαίρεση των προκλητών δυναμικών.....</i> | <i>198</i> |
| <i>Εικόνα 86: Η παρουσία του WEKA στο διαδίκτυο.....</i>                                                                                                                                                                                                         | <i>224</i> |
| <i>Εικόνα 87: Η οθόνη του Explorer του περιβάλλοντος WEKA .....</i>                                                                                                                                                                                              | <i>226</i> |

# Πίνακες

|                                                                                                                                                                    |     |
|--------------------------------------------------------------------------------------------------------------------------------------------------------------------|-----|
| Πίνακας 1 : Εγκεφαλικοί Ρυθμοί, συχνότητες και χαρακτηριστικά .....                                                                                                | 62  |
| Πίνακας 2 : Πίνακας Διαχείρισης Μεταχείρισης .....                                                                                                                 | 116 |
| Πίνακας 3 : Πίνακας Ανάλυσης Διακύμανσης Διασποράς ANOVA .....                                                                                                     | 119 |
| Πίνακας 4 : Οι Αλγόριθμοι Ταξινόμησης που χρησιμοποιήθηκαν .....                                                                                                   | 136 |
| Πίνακας 5 : Αποτελέσματα ταξινόμησης δεδομένων με δείκτη GFP.....                                                                                                  | 157 |
| Πίνακας 6 : Χρόνος Δημιουργίας Μοντέλου δεδομένων με δείκτη GFP.....                                                                                               | 158 |
| Πίνακας 7 : Sensitivity και Specifity δεδομένων με δείκτη GFP .....                                                                                                | 161 |
| Πίνακας 8 : Αποτελέσματα ταξινόμησης δεδομένων με δείκτη Power Spectral.....                                                                                       | 162 |
| Πίνακας 9 : Χρόνος Δημιουργίας Μοντέλου δεδομένων με δείκτη Power Spectral .....                                                                                   | 162 |
| Πίνακας 10 : Sensitivity και Specifity δεδομένων με δείκτη Power Spectral .....                                                                                    | 165 |
| Πίνακας 11 : Αποτελέσματα ταξινόμησης δεδομένων με δείκτη ERSP .....                                                                                               | 165 |
| Πίνακας 12 : Χρόνος Δημιουργίας Μοντέλου δεδομένων με δείκτη ERSP .....                                                                                            | 166 |
| Πίνακας 13 : Sensitivity και Specifity δεδομένων με δείκτη ERSP .....                                                                                              | 169 |
| Πίνακας 14 : Αποτελέσματα σωστής ταξινόμησης όλων των δεικτών ανά αλγόριθμο .....                                                                                  | 169 |
| Πίνακας 15 : Αποτελέσματα λανθασμένης ταξινόμησης όλων των δεικτών ανά αλγόριθμο .....                                                                             | 169 |
| Πίνακας 16 : Αποτελέσματα επί τις εκατό σωστής ταξινόμησης όλων των δεικτών ανά αλγόριθμο .....                                                                    | 170 |
| Πίνακας 17 : Εύκολες εικόνες που ταξινομήθηκαν ως εύκολες για τους τρεις δείκτες.....                                                                              | 172 |
| Πίνακας 18 : Δύσκολες εικόνες που ταξινομήθηκαν ως μη εύκολες για τους τρεις δείκτες.....                                                                          | 172 |
| Πίνακας 19 : Δείκτης Sencitivity για τους τρεις δείκτες.....                                                                                                       | 173 |
| Πίνακας 20 : Δείκτης Specificity για τους τρεις δείκτες.....                                                                                                       | 173 |
| Πίνακας 21 : Αποτελέσματα σωστής ταξινόμησης όλων των δεικτών ανά αλγόριθμο που χρησιμοποιήθηκαν στη διαδικασία ανάλυσης διακύμανσης ....                          | 177 |
| Πίνακας 22 : Πίνακας Διαχείρισης Μεταχείρισης .....                                                                                                                | 178 |
| Πίνακας 23 : Πίνακας Ανάλυσης Διακύμανσης Διασποράς ANOVA.....                                                                                                     | 178 |
| Πίνακας 24 : Αποτελέσματα σωστής και λανθασμένης ταξινόμησης του δείκτη GFP ανά αλγόριθμο, μετά τη βελτιστοποίηση με τον τον αλγόριθμο ConsistencySubsetEval ..... | 180 |
| Πίνακας 25 : Αποτελέσματα ταξινόμησης δεδομένων με δείκτη GFP μετά τη αφαίρεση της επίδρασης των προκλητών δυναμικών .....                                         | 191 |
| Πίνακας 26 : Χρόνος δημιουργίας μοντέλου δεδομένων με δείκτη GFP μετά τη αφαίρεση της επίδρασης των προκλητών δυναμικών .....                                      | 192 |
| Πίνακας 27 : Sensitivity και Specifity δεδομένων με δείκτη GFP μετά την αφαίρεση της επίδρασης των προκλητών δυναμικών .....                                       | 195 |
| Πίνακας 28 : Διαφορές ως προς το ποσοστό ορθών προβλέψεων των μοντέλων, ως προς τον δείκτη GFP πριν και μετά την αφαίρεση των προκλητών δυναμικών .....            | 196 |
| Πίνακας 29 : Συγκριτικός πίνακας ανάμεσα στις δύο μεθόδους βελτιστοποίησης πρόβλεψης του δείκτη GFP, πριν την αφαίρεση των προκλητών δυναμικών, μετά               |     |

|                                                                                                          |     |
|----------------------------------------------------------------------------------------------------------|-----|
| την αφαίρεση των προκλητών δυναμικών και μετά την εφαρμογή του<br>αλγόριθμου ConsistencySubsetEval ..... | 197 |
|----------------------------------------------------------------------------------------------------------|-----|



# Περιεχόμενα

|                                                                                            |    |
|--------------------------------------------------------------------------------------------|----|
| ΚΑΤΑΛΟΓΟΣ ΣΥΝΤΟΜΟΓΡΑΦΙΩΝ .....                                                             | 23 |
| I. ΕΙΣΑΓΩΓΗ.....                                                                           | 25 |
| 1. ΕΙΣΑΓΩΓΙΚΕΣ ΕΝΝΟΙΕΣ.....                                                                | 27 |
| 1.1 ΕΚΠΑΙΔΕΥΣΗ ΚΑΙ ΜΑΘΗΣΙΑΚΑ ΠΡΟΒΛΗΜΑΤΑ.....                                               | 27 |
| 1.2 Ο ΑΝΘΡΩΠΙΝΟΣ ΕΓΚΕΦΑΛΟΣ.....                                                            | 28 |
| 1.3 ΒΙΟΛΟΓΙΚΑ ΣΗΜΑΤΑ.....                                                                  | 31 |
| 1.4 ΝΟΗΣΗ ΚΑΙ ΕΚΠΑΙΔΕΥΣΗ.....                                                              | 32 |
| 1.5 ΣΚΟΠΟΣ ΚΑΙ ΣΤΟΧΟΙ ΤΗΣ ΠΑΡΟΥΣΑΣ ΔΙΔΑΚΤΟΡΙΚΗΣ ΔΙΑΤΡΙΒΗΣ.....                             | 32 |
| 1.6 ΣΥΝΟΨΗ ΤΗΣ ΔΙΑΤΡΙΒΗΣ.....                                                              | 35 |
| II. ΓΕΝΙΚΟ ΜΕΡΟΣ .....                                                                     | 37 |
| 2. ΒΙΒΛΙΟΓΡΑΦΙΚΗ ΕΡΕΥΝΑ .....                                                              | 39 |
| 2.1 ΣΤΑΣΙΜΑ ΣΗΜΕΙΑ.....                                                                    | 39 |
| 2.2 ΣΥΓΧΡΟΝΙΣΜΟΣ ΠΕΡΙΟΔΙΚΩΝ ΤΑΛΑΝΤΩΤΩΝ.....                                                | 40 |
| 2.3 ΤΑΞΙΝΟΜΗΣΗ ΚΑΙ ΚΑΤΗΓΟΡΙΟΠΟΙΗΣΗΣ ΔΕΙΚΤΩΝ .....                                          | 44 |
| 2.4 ΒΑΣΙΚΑ ΣΤΟΙΧΕΙΑ ΝΕΥΡΟΦΥΣΙΟΛΟΓΙΑΣ ΤΟΥ ΕΓΕΦΑΛΟΥ .....                                    | 48 |
| 2.4.1 Μετάδοση Νευρικού Ερεθίσματος .....                                                  | 48 |
| 2.4.2 Καταγραφή και ανάλυση βιολογικών σημάτων .....                                       | 52 |
| 2.5 ΣΤΟΙΧΕΙΑ ΗΛΕΚΤΡΟΕΓΚΕΦΑΛΟΓΡΑΦΗΜΑΤΟΣ .....                                               | 53 |
| 2.5.1 Συστήματα τοποθέτησης καλωδίων .....                                                 | 54 |
| 2.5.2 Ονοματολογία ηλεκτροδίων.....                                                        | 56 |
| 2.5.3 Μοντάζ.....                                                                          | 57 |
| 2.5.4 Εγκεφαλικοί Ρυθμοί.....                                                              | 58 |
| 3. ΜΕΘΟΔΟΙ ΕΠΕΞΕΡΓΑΣΙΑΣ ΚΑΙ ΚΑΤΗΓΟΡΙΟΠΟΙΗΣΗΣ ΣΗΜΑΤΩΝ.....                                  | 65 |
| 3.1 ΦΑΣΜΑΤΙΚΗ ΑΝΑΛΥΣΗ.....                                                                 | 66 |
| 3.1.1 Μη παραμετρικές μέθοδοι Φασματικής Ανάλυσης .....                                    | 68 |
| 3.1.2 Παραμετρικές μέθοδοι Φασματικής Ανάλυσης .....                                       | 69 |
| Γραμμικές Παραμετρικές μέθοδοι Φασματικής Ανάλυσης .....                                   | 70 |
| Μη Παραμετρικές γραμμικές μέθοδοι Φασματικής Ανάλυσης .....                                | 73 |
| 3.2 ΑΝΑΛΥΣΗ FOURIER .....                                                                  | 74 |
| 3.2.1 Μετασχηματισμός FOURIER.....                                                         | 75 |
| 3.2.2 Εφαρμογές Μετασχηματισμού Fourier .....                                              | 75 |
| 3.3 ΚΑΤΗΓΟΡΙΟΠΟΙΗΣΗ - ΤΑΞΙΝΟΜΗΣΗ ΣΗΜΑΤΩΝ .....                                             | 76 |
| 3.3.1 Γραμμικές και μη γραμμικές μέθοδοι.....                                              | 76 |
| Γραμμική μέθοδος.....                                                                      | 77 |
| Μη γραμμική μέθοδος.....                                                                   | 79 |
| 3.3.2 Μέθοδοι με επίβλεψη και χωρίς επίβλεψη.....                                          | 80 |
| 3.3.3 Τεχνητά Νευρωνικά Δίκτυα .....                                                       | 82 |
| Learning Vector Quantizer (LVQ).....                                                       | 83 |
| Νευρωνικό δίκτυο Τύπου Radial Basis Function (RBF).....                                    | 83 |
| 3.3.4 Εμπειρικές μέθοδοι Κατηγοριοποίησης / Ταυτοποίησης .....                             | 84 |
| Η θεμελιώδης αρχή της Μεθόδου .....                                                        | 84 |
| Ανάπτυξη αλγορίθμου κατασκευής κυρτού πολυγώνου. ....                                      | 85 |
| Τομή δύο κυρτών πολυγώνων.....                                                             | 86 |
| Υλοποίηση αλγορίθμων υπολογιστικής γεωμετρίας.....                                         | 86 |
| 3.4 ΜΕΘΟΔΟΙ ΠΡΟΕΠΕΞΕΡΓΑΣΙΑΣ .....                                                          | 86 |
| 3.4.1 Μέθοδοι προεπεξεργασίας για την εξαγωγή στάσιμων ιδιοτήτων σημάτων .....             | 86 |
| 3.4.2 Μέθοδοι προεπεξεργασίας για την απαλοιφή της επίδρασης των προκλητών δυναμικών ..... | 87 |

|                                                                                                                 |            |
|-----------------------------------------------------------------------------------------------------------------|------------|
| <b>III. ΕΙΔΙΚΟ ΜΕΡΟΣ.....</b>                                                                                   | <b>89</b>  |
| <b>4. ΜΕΘΟΔΟΙ ΠΟΥ ΑΝΑΠΤΥΧΘΗΚΑΝ &amp; ΜΑΘΗΜΑΤΙΚΟ ΥΠΟΒΑΘΡΟ.....</b>                                               | <b>91</b>  |
| <b>4.1 ΣΤΑΣΙΜΑ ΣΗΜΕΙΑ.....</b>                                                                                  | <b>91</b>  |
| <i>A) ο Αλγόριθμος ACC.....</i>                                                                                 | <i>92</i>  |
| <i>B) Πολυώνυμο Παρεμβολής.....</i>                                                                             | <i>94</i>  |
| <b>4.2 ΣΥΓΧΡΟΝΙΣΜΟΣ ΠΕΡΙΟΔΙΚΩΝ ΤΑΛΑΝΤΩΤΩΝ.....</b>                                                              | <b>95</b>  |
| <i>A) Συντελεστές Αυτοσυσχέτισης (Auto-Correlation Coefficients - ACC).....</i>                                 | <i>96</i>  |
| <i>B) Σταθερές Διασταυρούμενες Καμπύλες (Stable Cross Curves).....</i>                                          | <i>100</i> |
| <i>Γ) Συγχρονισμός (Synchronization).....</i>                                                                   | <i>100</i> |
| <b>4.3 ΤΑΞΙΝΟΜΗΣΗ ΚΑΙ ΚΑΤΗΓΟΡΙΟΠΟΙΗΣΗΣ ΔΕΙΚΤΩΝ.....</b>                                                         | <b>101</b> |
| <b>4.3.1 Οι Νευροφυσιολογικοί Δείκτες που μελετήθηκαν.....</b>                                                  | <b>103</b> |
| <b>4.3.2 Global Field Power (GFP).....</b>                                                                      | <b>103</b> |
| <b>4.3.3 Προκλητά Δυναμικά (Event Related Potential - ERPs).....</b>                                            | <b>106</b> |
| <b>4.3.4 Φασματικές Διαταραχές Σχετιζόμενες με το Γεγονός (Event Related Spectral Perturbation -ERSPs).....</b> | <b>113</b> |
| <b>4.3.5 Inter Trial Coherence - ITCs.....</b>                                                                  | <b>114</b> |
| <b>4.3.6 Φασματική Ισχύς Σήματος - Power Spectral.....</b>                                                      | <b>114</b> |
| <b>4.4 ΑΝΑΛΥΣΗ ΔΙΑΚΥΜΑΝΣΗΣ.....</b>                                                                             | <b>115</b> |
| <b>5. ΣΥΝΘΗΚΕΣ &amp; ΕΡΓΑΛΕΙΑ.....</b>                                                                          | <b>121</b> |
| <b>5.1 ΠΕΡΙΓΡΑΦΗ ΣΥΝΘΗΚΩΝ ΠΕΙΡΑΜΑΤΟΣ ΚΑΙ ΔΕΔΟΜΕΝΑ.....</b>                                                      | <b>121</b> |
| <b>5.2 ΧΩΡΙΚΗ ΔΙΑΤΑΞΗ ΗΛΕΚΤΡΟΔΙΩΝ.....</b>                                                                      | <b>126</b> |
| <b>5.3 ΤΟ ΠΕΡΙΒΑΛΛΟΝ ΕΕGLAB.....</b>                                                                            | <b>128</b> |
| <b>5.4 ΔΙΑΔΙΚΑΣΙΑ ΕΞΑΓΩΓΗΣ ΕΠΟΧΩΝ.....</b>                                                                      | <b>130</b> |
| <b>5.5 ΤΑΞΙΝΟΜΗΤΕΣ – ΤΟ ΠΕΡΙΒΑΛΛΟΝ WEKA.....</b>                                                                | <b>131</b> |
| <b>5.5.1 Η μορφή των δεδομένων ARFF.....</b>                                                                    | <b>132</b> |
| <b>5.5.2 Ταξινόμηση (Classification).....</b>                                                                   | <b>135</b> |
| <b>5.5.3 Αλγόριθμοι Ταξινόμησης που χρησιμοποιήσαμε.....</b>                                                    | <b>136</b> |
| <b>5.5.4 Επεξήγηση των αποτελεσμάτων από το WEKA.....</b>                                                       | <b>137</b> |
| <b>6. ΠΕΙΡΑΜΑΤΙΚΑ ΑΠΟΤΕΛΕΣΜΑΤΑ – ΣΧΟΛΙΑΣΜΟΣ - ΣΥΜΠΕΡΑΣΜΑΤΑ.....</b>                                             | <b>141</b> |
| <b>6.1 ΕΝΤΟΠΙΣΜΟΣ ΣΤΑΣΙΜΩΝ ΣΗΜΕΙΩΝ ΚΑΙ ΑΤΡΑΚΤΩΝ ΣΤΑΣΙΜΩΝ ΚΥΜΑΤΩΝ.....</b>                                       | <b>141</b> |
| <b>6.2 ΣΥΓΧΡΟΝΙΣΜΟΣ ΜΕ ΔΙΑΔΙΚΑΣΙΑ ΣΤΑΘΕΡΗΣ ΠΕΡΙΟΔΟΥ.....</b>                                                    | <b>147</b> |
| <b>6.3 ΑΛΓΟΡΙΘΜΙΚΑ ΜΟΝΤΕΛΑ ΚΑΤΗΓΟΡΙΟΠΟΙΗΣΗΣ ΜΕ ΔΕΙΚΤΕΣ.....</b>                                                 | <b>153</b> |
| <b>6.3.1 Λεπτομέρειες της Ταξινόμησης.....</b>                                                                  | <b>155</b> |
| <b>6.3.2 Δείκτης GFP.....</b>                                                                                   | <b>157</b> |
| <b>6.3.3 Δείκτης Φασματικής Ισχύος (Power Spectral).....</b>                                                    | <b>161</b> |
| <b>6.3.4 Δείκτης ERSP.....</b>                                                                                  | <b>165</b> |
| <b>6.3.5 Συγκεντρωτική σύγκριση επίδοσης Ταξινομητών.....</b>                                                   | <b>169</b> |
| <b>6.3.6 Συγκεντρωτική σύγκριση Sensitivity και Specificity.....</b>                                            | <b>172</b> |
| <b>6.3.7 Εξαγωγή καλύτερου μοντέλου πρόβλεψης.....</b>                                                          | <b>175</b> |
| <i>Ανάλυση διακύμανσης.....</i>                                                                                 | <i>176</i> |
| <i>Βελτίωση προβλεψιμότητας.....</i>                                                                            | <i>179</i> |
| <b>6.3.8 Σχολιασμός Αποτελεσμάτων με βάση τα διαγράμματα.....</b>                                               | <b>182</b> |
| <i>Σχολιασμός διαγραμμάτων Global Field Power (GFP).....</i>                                                    | <i>182</i> |
| <i>Σχολιασμός οπτικοποίησης εγκεφαλικής δραστηριότητας.....</i>                                                 | <i>186</i> |
| <b>6.3.9 Αφαίρεση της Επίδρασης των Προκλητών Δυναμικών.....</b>                                                | <b>189</b> |
| <b>6.4 ΣΥΜΠΕΡΑΣΜΑΤΑ ΚΑΙ ΜΕΛΛΟΝΤΙΚΗ ΕΡΕΥΝΑ.....</b>                                                              | <b>198</b> |
| <b>ΒΙΒΛΙΟΓΡΑΦΙΑ.....</b>                                                                                        | <b>209</b> |
| <b>ΠΑΡΑΡΤΗΜΑ Α.....</b>                                                                                         | <b>223</b> |
| <b>ΓΕΝΙΚΑ ΓΙΑ ΤΟ WEKA.....</b>                                                                                  | <b>223</b> |
| <b>ΑΝΟΙΓΟΝΤΑΣ ΤΟ WEKA.....</b>                                                                                  | <b>225</b> |
| <b>ΑΝΟΙΓΟΝΤΑΣ ΤΟΝ EXPLORER.....</b>                                                                             | <b>225</b> |
| <b>PREPROCESSING.....</b>                                                                                       | <b>226</b> |
| <b>ΠΑΡΑΡΤΗΜΑ Β.....</b>                                                                                         | <b>229</b> |

|                                                         |            |
|---------------------------------------------------------|------------|
| <b>ΜΕΤΑΣΧΗΜΑΤΙΣΜΟΣ FOURIER ΠΕΡΙΟΔΙΚΩΝ ΣΗΜΑΤΩΝ .....</b> | <b>229</b> |
| <i>Περιοδικά σήματα .....</i>                           | <i>229</i> |
| <i>Απεριοδικά σήματα .....</i>                          | <i>229</i> |
| <b>ΙΔΙΟΤΗΤΕΣ ΜΕΤΑΣΧΗΜΑΤΙΣΜΟΥ FOURIER (DTFT) .....</b>   | <b>229</b> |
| <i>Γραμμικότητα .....</i>                               | <i>229</i> |
| <i>Μετατόπιση.....</i>                                  | <i>229</i> |
| <i>Αντιστροφή στο χρόνο .....</i>                       | <i>230</i> |
| <i>Διαμόρφωση .....</i>                                 | <i>230</i> |
| <i>Το θεώρημα της Συνέλιξης .....</i>                   | <i>230</i> |
| <i>Το Θεώρημα του Parseval.....</i>                     | <i>230</i> |



# Κατάλογος Συντομογραφιών

|        |                                     |
|--------|-------------------------------------|
| AAC    | Autocorrelation Components          |
| AEP    | Auditory Evoked Potentials          |
| AIC    | Akaike Information Criterion        |
| ANOVA  | Analysis of Variance                |
| AR     | Autoregressive                      |
| ARMA   | Autoregressive - Moving Average     |
| BCI    | Brain-Computer Interface            |
| BEPD   | Brain Evoked Potential Data         |
| CAR    | Common Average Reference            |
| CGA    | Computational Geometry Algorithms   |
| DTF    | Discrete Transform Fourier          |
| EEG    | Ηλεκτροεγκεφαλογράφημα              |
| ERP    | Event Related Potential             |
| ERSP   | Event Related Spectral Perturbation |
| FFT    | Fast Fourier Transform              |
| GFP    | Global Field Power                  |
| ITC    | Inter Trial Coherence               |
| LVQ    | Learning Vector Quantizer           |
| MA     | Moving Average                      |
| O(...) | Πολυπλοκότητα Αλγόριθμου            |
| PLV    | Phase Locking Value                 |
| PS     | Power Spectra                       |
| PSD    | Power Spectral Density              |
| RBF    | Radial Basis Function               |
| RT     | Reaction Time                       |
| SEP    | Somatosensory Evoked Potentials     |
| SNR    | Signal to Noise Ratio               |
| SOM    | Self Organising Map                 |
| VEP    | Visual Evoked Potentials            |
| HEΓ    | Ηλεκτροεγκεφαλογράφημα              |
| ΠΔ     | Προκλητά Δυναμικά                   |
| TN     | Τεχνητοί Νευρώνες                   |
| TNΔ    | Τεχνητό Νευρωνικό Δίκτυο            |
| ΦΑ     | Φασματική Ανάλυση                   |



## I. ΕΙΣΑΓΩΓΗ





# 1. ΕΙΣΑΓΩΓΙΚΕΣ ΕΝΝΟΙΕΣ

## 1.1 Εκπαίδευση και Μαθησιακά Προβλήματα

Κατά τη διάρκεια μιας εκπαιδευτικής διαδικασίας ο εγκέφαλος δραστηριοποιείται έντονα. Η ένταση ποικίλει ανάλογα με το αν το άτομο δυσκολεύεται ή όχι. Η πρόβλεψη της δυσκολίας που αισθάνεται κάποιο άτομο κατά τη διάρκεια της εκπαιδευτικής διαδικασίας είναι αντικείμενο μελέτης πολλών ερευνητών [29],[50],[51],[85],[142],[143]. Οι επιστήμες της Νευροανάδρασης (Neurofeedback), της Νευροαπεικόνισης (Neuroimaging), της Βιοανάδρασης (Biofeedback), της Νευροανάλυσης (Neuro-analysis), της Νευροοπτικοποίησης (Neurovision), κ.τ.λ. είναι μερικά μόνο πεδία των επιστημών τα οποία ασχολούνται με εκπαίδευση και νευροφυσιολογία. Η πρόβλεψη της δυσκολίας που συναντά ένα άτομο κατά τη διάρκεια μιας εκπαιδευτικής διαδικασίας μπορεί να βοηθήσει στην επίλυση μαθησιακών προβλημάτων, όπως αυτό της συγκέντρωσης, του άγχους κ.τ.λ. [4], [8], [21].

Τα δεδομένα από τις σύγχρονες νευροαπεικονιστικές μεθόδους και τις νευροεπιστήμες που σχετίζονται με τη γνώση, προσφέρουν σημαντικές πληροφορίες σχετικά με το πώς οι άνθρωποι ανταποκρίνονται σε αισθητηριακά δεδομένα και για το πώς εκτελούν γνωσιακές διαδικασίες. Η διαδικασία αυτή επιτρέπει μια καλύτερη κατανόηση των νευρωνικών δικτύων του εγκεφάλου και μια καλύτερη κατανόηση των διαδικασιών με τις οποίες αυτά αναπαράγονται ή για τον τρόπο με τον οποίο σχετίζονται με συναφείς προς την εκπαίδευση έννοιες, όπως η συγκέντρωση, η προσοχή, η μνήμη, η μάθηση και η δημιουργική επίλυση προβλημάτων. Τα τελευταία χρόνια γίνεται μεγάλη συζήτηση στον επιστημονικό χώρο σχετικά με την ανάγκη τα δεδομένα που υπάρχουν από τις έρευνες στις Νευροεπιστήμες να αρχίσουν να εφαρμόζονται στο χώρο της εκπαίδευσης, με σκοπό βέβαια τη βελτίωση της εκπαιδευτικής διαδικασίας.

Διάφορες μαθησιακές δυσκολίες περιγράφονται στα [142][143][169]. Οι συγγραφείς παραθέτουν έναν μεγάλο αριθμό μαθησιακών προβλημάτων τα οποία είτε οφείλονται σε ψυχολογικούς είτε σε παθολογικούς λόγους :

- Ψυχικά προβλήματα, νευρωτικές καταστάσεις, παιδικές ψυχώσεις, διαταραχή συμπεριφοράς, αντιδράσεις προσαρμογής κ.τ.λ.
- Ειδικές καθυστερήσεις στην εξέλιξη, δυσλεξία, δυσαριθμησία, διαταραχή στην ανάπτυξη του λόγου κ.τ.λ..
- Προβλήματα από το νοητικό επίπεδο, νοητική καθυστέρηση, οριακές καταστάσεις νοημοσύνης, ακόμη και υψηλή νοημοσύνη
- Παθολογικές καταστάσεις, διαταραχές όρασης και ακοής, κινητικές δυσκολίες, χρόνια νοσήματα, επιληψία, κ.τ.λ.
- Ψυχοκοινωνικές καταστάσεις, πολιτισμική αποστέρηση, ανεπαρκείς συνθήκες διαβίωσης, δυσμενείς οικογενειακές συνθήκες, κ.τ.λ.


Στην παρούσα διδακτορική διατριβή αναπτύσσονται νέες μέθοδοι και μοντέλα πρόβλεψης μαθησιακών δυσκολιών κατά τη διάρκεια μιας εκπαιδευτικής διαδικασίας, με τη βοήθεια ψηφιακής ανάλυσης ΗΕΓ δεδομένων μέσω κατάλληλων πληροφοριακών συστημάτων και λογισμικών. Επίσης αναπτύσσονται νέες μέθοδοι ανίχνευσης στάσιμων κυμάτων σε ΗΕΓ, τα οποία βοηθούν στην πρόβλεψη και στην αποκάλυψη τάσης σε μια εκπαιδευτική διαδικασία.

(Αναλυτικά οι σκοποί και στόχοι της διδακτορικής διατριβής, παρατίθενται στην παράγραφο 1.5)

## **1.2 Ο Ανθρώπινος Εγκέφαλος**

Ο ανθρώπινος εγκέφαλος (**Εικόνα 1**) είναι κοινά αποδεκτό ότι αποτελεί ένα εξαιρετικά πολύπλοκο δημιούργημα της φύσης. Ένα δημιούργημα το οποίο εμπεριέχει ένα εξαιρετικά πολύπλοκο σύνθετο δίκτυο κύτταρων, οι λειτουργίες του οποίου είναι υπεύθυνες για τη λειτουργία της μνήμης, τη δημιουργία των

σκέψεων, τον έλεγχο των δραστηριοτήτων του σώματος και της εκδήλωσης των συναισθημάτων και έχει μάζα μόλις 1.5kg [90].



*Εικόνα 1: Ο Ανθρώπινος Εγκέφαλος*  
(public domain image, free to use, share or modify, even commercially)

Για να πραγματοποιηθούν αυτές οι λειτουργίες, πρέπει να συνεργαστούν δισεκατομμύρια νευρώνες, οι οποίοι μέσω ηλεκτρικών σημάτων και με εξαιρετικά μεγάλη ταχύτητα, μεταφέρουν διάφορα μηνύματα από μια περιοχή του εγκεφάλου σε μια άλλη. Δεν υπάρχει συσκευή η οποία μπορεί να προσομοιώσει τις λειτουργίες αυτού του καταπληκτικού οργάνου. Πολλοί προσομοιάζουν έναν υπολογιστή με έναν εγκέφαλο, όμως στην πραγματικότητα αυτό δεν είναι αλήθεια. Η έρευνα για την κατανόηση των μηχανισμών λειτουργίας του είναι συνεχής και παρά την τεχνολογική εξέλιξη της εποχής μας, είναι γενικώς αποδεκτό ότι ελάχιστα ξέρουμε για αυτόν. Το πεδίο φαίνεται απέραντο και η πρόοδος των ανακαλύψεων, έστω και των τελευταίων πιο προχωρημένων τεχνολογικά 200 ετών, μας ωθεί συνεχώς σε νέες ανεξερεύνητες περιοχές [91].

Ο εγκέφαλος έχει την ικανότητα να τροποποιείται τόσο μορφολογικά, όσο και λειτουργικά, ως απάντηση σε αλλαγές στο περιβάλλον και τη γνώση. Η ιδιότητα αυτή του εγκεφάλου ονομάζεται «πλαστικότητα» [167]. Η ιδιότητα της «πλαστικότητας» είναι αυτή που του επιτρέπει να «μαθαίνει». Σήμερα, η

Νευροεπιστήμη παρέχει συνεχώς δεδομένα που αυξάνουν ταχέως και επιπλέον διαθέτει μηχανισμούς τόσο σε μοριακό και κυτταρικό επίπεδο, όσο και στο επίπεδο των νευρωνικών κυκλωμάτων, που διαμεσολαβούν και υποβοηθούν τις διεργασίες της μάθησης και της μνήμης. Πολλές φορές όμως η πλαστικότητα αυτή δεν είναι εύκολη, επειδή υπάρχουν προβλήματα και δυσκολίες κατά τη διαδικασία της μάθησης.

Ο εγκέφαλος, προκειμένου να επιτελέσει μια δράση, ενεργοποιείται πριν το άτομο αποφασίσει να δράσει [137]. Το γεγονός αυτό υποδηλώνει ότι στην πραγματικότητα τα άτομα δεν παίρνουν αποφάσεις αλλά ότι η απόφαση έχει ήδη ληφθεί. Την πραγματικότητα αυτή εκμεταλλεύονται μεγάλες διαφημιστικές εταιρείες για την προώθηση κάποιων προϊόντων, εκμεταλλευόμενες τη λειτουργία αυτή του εγκεφάλου, προκειμένου να ελέγξουν καταναλωτικές συμπεριφορές.

Υπηρεσίες Ασφάλειας, όπως η CIA και το FBI επενδύουν μεγάλα κεφάλαια στην ανάπτυξη μεθόδων, οι οποίες θα επιτρέπουν τη διαπίστωση μια κατάστασης και μόνο με τη σκέψη, όπως οι ανιχνευτές ψεύδους. Με τέτοιες μεθόδους προσπαθούν να αναγνωρίσουν νοητική προετοιμασία ψεύδους, που προηγείται στον εγκέφαλο της εκφοράς του ψέματος. Έτσι θα μπορεί κάποιος να ανγνωρίσει ποιος ψεύδεται πριν καν ο «ψεύτης» μιλήσει.

Μια τέτοια συμπεριφορά του εγκεφάλου θα μπορούσαμε να εκμεταλλευτούμε και με τα αποτελέσματα της παρούσας εργασίας. Ο προβλεπτικός μηχανισμός που παρουσιάζεται στην παρούσα εργασία μπορεί να αποτελέσει τη διαδικασία για πυροδότηση συμπεριφοράς της διαδικασίας μάθησης η οποία θα προσαρμόζεται στη δυσκολία μάθησης. Δηλαδή το σύστημα θα αντιλαμβάνεται τη δυσκολία που αισθάνεται κάποιο άτομο που προσπαθεί να μάθει και να κατανοήσει, πριν ακόμα δυσκολευτεί.

### 1.3 Βιολογικά σήματα

Τα Βιολογικά σήματα θεωρούνται χωρικές, χρονικές ή χωροχρονικές καταγραφές ενός βιολογικού γεγονότος [131]. Τέτοια γεγονότα είναι οι ιδέες, οι σκέψεις στον εγκέφαλο, μια παλλόμενη καρδιά ή ένας συσπώμενος μυς.

Κατά τη διάρκεια διάφορων βιολογικών διεργασιών υπάρχει ηλεκτρική, χημική, και μηχανική δραστηριότητα και παράγονται σήματα που μπορούν να μετρηθούν και να αναλυθούν. Τα βιολογικά σήματα εμπεριέχουν πληροφορίες που μπορούν να χρησιμοποιηθούν, για να εξηγήσουν τους φυσιολογικούς μηχανισμούς που υποκρύπτονται σε ένα συγκεκριμένο βιολογικό γεγονός ή ένα σύστημα [144].

Το ηλεκτροεγκεφαλογράφημα (ΗΕΓ) αποτελεί καταγραφή τέτοιων βιολογικών σημάτων. Πιο συγκεκριμένα, ΗΕΓ είναι η καταγραφή του ηλεκτρικού πεδίου του ανθρώπινου εγκεφάλου. Για πρώτη φορά έγινε το 1924 από τον H. Berger [155], ο οποίος έδωσε και το όνομα Electroencephalography (EEG). Το ΗΕΓ βασίζεται στην καταγραφή διαφορών δυναμικού του φλοιού του εγκεφάλου. Αυτές οι διαφορές δυναμικού παρουσιάζονται στο τριχωτό της κεφαλής, ως αποτέλεσμα της λειτουργίας του εγκεφάλου.

Η μελέτη, η καταγραφή και η ανάλυση του Ηλεκτροεγκεφαλογραφήματος (ΗΕΓ) έχει πολύ σημαντική συμβολή στην ανάλυση και τη βελτίωση της εκπαιδευτικής διαδικασίας. Στην παράγραφο 1.1 παραθέσαμε έναν μεγάλο αριθμό παραγόντων που προκαλούν μαθησιακές δυσλειτουργίες. Υπάρχουν παθογενείς καταστάσεις, ψυχολογικές καταστάσεις, κοινωνικοοικονομικές καταστάσεις, κ.τ.λ., οι οποίες σχετίζονται με μαθησιακά προβλήματα. Μέσα από τη μελέτη του ΗΕΓ γίνεται προσπάθεια να βελτιωθούν τέτοιες προβληματικές καταστάσεις (π.χ. Μαθηματικό άγχος, Προβλήματα της μνήμης εργασίας (working memory), Άγχος και Μαθησιακή Επίδοση, Δυσλεξία, Developmental Dyscalculia κα ) [1] - [21]

#### **1.4 Νόηση και Εκπαίδευση**

Η Νόηση και η Εκπαίδευση ήταν πάντα έννοιες αλληλένδετες [21] [4]. Από τα αρχαία χρόνια η μέτρηση της νόησης ήταν άμεσα συνδεδεμένη με τις ικανότητες για κατανόηση εννοιών που σχετίζονται με την εκπαίδευση, όπως οι μαθηματικοί όροι και τα θεωρήματα ή οι κανόνες της φυσικής. Η Νόηση έχει πολλούς ορισμούς. Κατά μια έννοια είναι η σκέψη, ο συνδυασμός, η δυνατότητα αποθήκευσης και επεξεργασίας μηνυμάτων, εικόνων και ιδεών, η εξαγωγή πληροφορίας, η αιτιολόγηση, η απόκτηση γνώσεων. Οι διαδικασίες αυτές είναι άμεσα συνδεδεμένες με τα Μαθηματικά, τη Φυσική, την Πληροφορική κ.τ.λ..

#### **1.5 Σκοπός και στόχοι της παρούσας Διδακτορικής Διατριβής**

Σκοπός της παρούσας διδακτορικής διατριβής είναι η ανακάλυψη νέων μεθόδων πρόβλεψης μαθησιακών δυσκολιών που αισθάνεται ένα άτομο κατά τη διάρκεια μιας εκπαιδευτικής διαδικασίας, χρησιμοποιώντας κατάλληλα πληροφοριακά συστήματα και μεθόδους ψηφιακής ανάλυσης ηλεκτροεγκεφαλογραφικού σήματος.

Χρησιμοποιώντας κατάλληλα εργαλεία ανακαλύφθηκε και μοντελοποιήθηκε η δυσκολία που συναντά ένα άτομο την ώρα που εκτελεί μια εκπαιδευτική διαδικασία. Η ανακάλυψη των χαρακτηριστικών της δυσκολίας αυτής μπορεί να οδηγήσει στην παραγωγή κατάλληλων συστημάτων, τα οποία μπορούν να παρέχουν προσαρμοσμένη διαδικασία μάθησης (adaptive learning) ανάλογα με το πρόβλημα ή τις μαθησιακές δυσκολίες που έχει κάθε άτομο.

Μέσα από ίδιες διαδικασίες μοντελοποιήθηκε και στη συνέχεια χρησιμοποιήθηκε η δυσκολία, προκειμένου να ανακαλυφθούν μαθησιακές δυσκολίες οι οποίες βασίζονται σε παρόμοιες εγκεφαλικές διεργασίες. Μαθησιακές δυσκολίες, οι οποίες μπορούν να συνδεθούν με τη βελτίωση

προσοχής, τη βελτίωση της συμπεριφοράς του εκπαιδευόμενου, τη βελτίωση της συγκέντρωσης, την πρόβλεψη της δυσκολίας του ασκούμενου, την πρόβλεψη συμπεριφοράς, την πρόβλεψη άγχους. Η αίσθηση τέτοιων δυσκολιών μπορεί τελικά να προβλεφθεί και μέσα από τη διατριβή προτείνονται αλγοριθμικά μοντέλα τα οποία μπορούν να κάνουν σωστές προβλέψεις.

Παράλληλα μελετήθηκαν χρονολογικές σειρές οι οποίες μπορούν να δώσουν χρήσιμα συμπεράσματα σχετικά με τη δυνατότητα πρόβλεψης συμπεριφοράς και πρόβλεψη τάσης συμπεριφοράς. Οι πληροφορίες που μπορούν να δώσουν σχετίζονται με την τάση, την εποχικότητα και τις κυκλικές κυμάνσεις της. Μια στοχαστική διαδικασία χαρακτηρίζεται ως στάσιμη, όταν οι στατιστικές της ιδιότητες δεν επηρεάζονται από μια μεταβολή στην αρχή του χρόνου. Δηλαδή, οι στατιστικές ιδιότητες των  $N$  παρατηρήσεων με αρχή  $t$  ( $y_t, y_{t+1}, \dots, y_{t+N+1}$ ) είναι οι ίδιες με τις στατιστικές ιδιότητες των  $N$  παρατηρήσεων με αρχή την περίοδο  $t+k$  ( $y_{t+K}, y_{t+K+1}, \dots, y_{t+K+N+1}$ ). [9], [25], [28], [47], [58], [70], [103], [102]

Γενικά, μια χρονολογική σειρά θα είναι στάσιμη, αν ο μέσος και η διακύμανσή της δεν μεταβάλλονται με το χρόνο και η συνδιακύμανση μεταξύ των τιμών της σε δύο χρονικά σημεία εξαρτάται μόνο από την απόσταση ανάμεσα σ' αυτά τα χρονικά σημεία και όχι από τον ίδιο το χρόνο. Η μελέτη του HEΓ, από την πλευρά της στασιμότητας, είναι ανοικτό πεδίο έρευνας. [25], [47], [102], [103].

Για την εξαγωγή χρήσιμων συμπερασμάτων πρόβλεψης μιας εκπαιδευτικής διαδικασίας, **αναπτύχθηκαν τρεις νέες μέθοδοι**, με τις οποίες αναλύθηκαν τα δεδομένα από ένα Ηλεκτροεγκεφαλογράφημα. Η πρώτη μέθοδος βασίστηκε στα μαθηματικά και αποτελεί έναν νέο αλγόριθμο μελέτης στασιμότητας ενός EEG σήματος, ή δεύτερη μέθοδος είναι πειραματική και εξετάζει το φαινόμενο του συγχρονισμού φάσης, ενώ η τρίτη μέθοδος βασίζεται στη μελέτη, την ανάλυση και τέλος την ταξινόμηση-κατηγοριοποίηση των δεικτών με τη βοήθεια κατάλληλων λογισμικών και αλγορίθμων.

Γενικά, ένα ΗΕΓ σήμα είναι ένα πολυσύνθετο μη στάσιμο σήμα [102], [103]. Είναι πολύ δύσκολο να αναγνωριστούν ιδιαίτερα χαρακτηριστικά του, όπως βιομετρικά πρότυπα (biometric patterns) ή παθολογικές αλλοιώσεις. **Σύμφωνα με την πρώτη μέθοδο**, χρησιμοποιώντας μια επαναλαμβανόμενη διαδικασία Αυτοσυσχέτισης και Συμμετρικά Χαρακτηριστικά του ηλεκτροεγκεφαλογραφήματος, το οποίο μπορεί να προσομοιαστεί και με μια χρονολογική σειρά, διερευνώνται πειραματικά σταθερά σημεία που πιθανώς υπάρχουν σε EEG σήματα. Σκοπός της εργασίας ήταν να αναγνωριστούν σταθερά σημεία και σταθερές κυματομορφές σε EEG σήματα. Επίσης ερευνήθηκε ο σχηματισμός ατράκτων στάσιμων κυμάτων γύρω από αυτά τα σταθερά σημεία, οι οποίες αποκαλύπτουν την ύπαρξη σταθερών κυματιδίων σήματος ΗΕΓ.

Το χαρακτηριστικό του συγχρονισμού των περιοδικών ταλαντωτών βασίζεται στην εξαγωγή μιας ειδικής μεταβλητής, της φάσης. Αυτό το φαινόμενο θεωρείται ως ένα πολύ σημαντικό ζήτημα σε ένα ευρύ φάσμα επιστημών. Ωστόσο, μέχρι τώρα η έρευνα των φαινομένων συγχρονισμού χρειάζεται ένα μεγάλο σύνολο δεδομένων και επίσης απαιτείται τα δεδομένα αυτά να έχουν ίδια περίοδο. Στην παρούσα διδακτορική διατριβή, **σύμφωνα με τη δεύτερη μέθοδο**, αναπτύχθηκε μια εντελώς νέα προσέγγιση του συγχρονισμού [6], [44], η οποία βασίστηκε στη μέτρηση μικρών συνόλων δεδομένων, χρησιμοποιώντας μια νέα τεχνική, σύμφωνα με την οποία κατασκευάστηκε μια διαδικασία σταθερής περιόδου για κάθε μια από τις ακολουθίες μικρού συνόλου δεδομένων που εξετάστηκε. Η έρευνα βασίστηκε σε πειραματικά αποτελέσματα.

**Στο τρίτο μέρος** της έρευνάς μας αναπτύχθηκε μια εντελώς νέα μέθοδος μελέτης, ταξινόμησης και κατηγοριοποίησης δεικτών, οι οποίοι επέτρεψαν να αναγνωριστούν οι δυσκολίες που συναντούν τα άτομα κατά την εκτέλεση εκπαιδευτικών δραστηριοτήτων. Ανακαλύφθηκαν μέθοδοι ανάλυσης Νευροφυσιολογικών (ή Ηλεκτροφυσιολογικών) δεικτών [64], [112], [128], [131], [146], με σκοπό να αναγνωριστούν και να προβλεφτούν αυτές οι δυσκολίες που συναντά κάποιος κατά τη διάρκεια εκπαιδευτικών διεργασιών. Πιο συγκεκριμένα, χρησιμοποιήθηκε ο Global Field Power (GFP), ένας δείκτης ο



οποίος αντιπροσωπεύει τη χωρική τυπική απόκλιση των προκλητών δυναμικών στον χάρτη του εγκεφάλου. Επίσης χρησιμοποιήθηκαν Προκλητά Δυναμικά (Evoked Related Potentials – ERPs), Φασματικές Διαταραχές σχετικές με το γεγονός (Event Related Spectral Perturbation – ERSPs) και η Φασματική Ισχύς Σήματος (Power Spectra). Τέλος ερευνήθηκαν και άλλοι δείκτες, όπως ο Inter Trial Coherence - ITCs) και οι Εντροπίες (Shannon, Δείγματος (Sample Entropy), Κυματιδικές εντροπίες (Wavelet Entropy), Log energy entropy, Threshold entropy, Sure entropy, Norm entropy). Τέλος χρησιμοποιήθηκαν μέθοδοι ταξινόμησης – κατηγοριοποίησης, έτσι ώστε να βρεθούν κατάλληλα μαθηματικά μοντέλα πρόβλεψης της περιγραφείσας δυσκολίας σε μια εκπαιδευτική διαδικασία.

Τέτοιες διαδικασίες πρόβλεψης δυσκολίας, όπως περιγράφουμε και στην παράγραφο 1.2, θα μπορούσαν να χρησιμοποιηθούν σε μηχανισμούς πρόβλεψης της δυσκολίας που θα αντιμετωπίσει ένα άτομο, πριν ακόμα τις αντιμετωπίσει.

## **1.6 Σύνοψη της διατριβής**

Στο 2<sup>ο</sup> κεφάλαιο πρατίζεται εκτενώς η βιβλιογραφική έρευνα σχετικά με βασικές έννοιες από τη βιβλιογραφία, οι οποίες αποτελούν βασικές γνώσεις για τη συγκεκριμένη διδακτορική διατριβή. Έτσι αναλύουμε έννοιες, όπως η ανάλυση χρονοσειρών, τα στάσιμα κύματα, τα σταθερά σημεία, ο συγχρονισμός των περιοδικών ταλαντώσεων, η ταξινόμηση και η κατηγοριοποίηση, ο εγκέφαλος, οι ρυθμοί του ηλεκτροεγκεφαλογράφηματος, οι κορυφές των προκλητών δυναμικών.

Στο 3<sup>ο</sup> κεφάλαιο αναλύονται σύντομα βασικές έννοιες που αφορούν τη φασματική ανάλυση και την ανάλυση σημάτων, οι οποίες χρησιμοποιούνται στην ανάλυση των ηλεκτροεγκεφαλογραφικών σημάτων. Εξηγούμε αναλυτικά ποια μαθηματικά μοντέλα χρησιμοποιήθηκαν, προκειμένου να εξαχθούν οι κατάλληλοι δείκτες οι οποίοι χρησιμοποιούνται για την εξαγωγή των

αποτελεσμάτων της παρούσας διατριβής. Γίνεται αναφορά στην ανάλυση Fourier, η οποία χρησιμοποιείται στην ανίχνευση στάσιμων σημείων και τέλος υπάρχει αναφορά στις έννοιες της κατηγοριοποίησης και ταξινόμησης οι οποίες αποτελούν την τελική μέθοδο αξιολόγησης των δεικτών, με σκοπό να βρεθούν τα κατάλληλα μαθηματικά μοντέλα, ώστε να επιτευχθεί η πρόβλεψη της δυσκολίας που αντιμετωπίζει ο εγκέφαλος κατά τη διάρκεια μιας εκπαιδευτικής διαδικασίας. Επίσης γίνεται αναφορά στην προεπεξεργασία ενός σήματος.

Στο 4<sup>ο</sup> κεφάλαιο παραθέτουμε τις μεθόδους που αναπτύξαμε για την πραγματοποίηση της έρευνάς μας. Επίσης αναφέρουμε τα εργαλεία καθώς και το μαθηματικό υπόβαθρο και τις ψηφιακές τεχνικές ανάλυσης στα οποία βασιστήκαμε, προκειμένου να ολοκληρωθεί η εργασία μας.

Στο 5<sup>ο</sup> κεφάλαιο παρατίθενται τα εργαλεία, οι συνθήκες και το είδος των δεδομένων του πειράματος που χρησιμοποιήθηκαν στη διατριβή. Έτσι περιγράφουμε τα δεδομένα και τα λογισμικά που χρησιμοποιήσαμε, καθώς και τον τρόπο διασύνδεσης των ηλεκτροδίων.

Στο 6<sup>ο</sup> κεφάλαιο αναλύουμε τα πειραματικά αποτελέσματα που προέκυψαν κατά τη διάρκεια της έρευνάς μας, βρίσκουμε τα καλύτερα μοντέλα πρόβλεψης και εξάγουμε συμπεράσματα. Επίσης καταγράφουμε σκέψεις για μελλοντική έρευνα.

## **II. ΓΕΝΙΚΟ ΜΕΡΟΣ**



## 2. ΒΙΒΛΙΟΓΡΑΦΙΚΗ ΕΡΕΥΝΑ

### 2.1 Στάσιμα Σημεία

Η ανάλυση χρόνου-συχνότητας ενός ηλεκτροεγκεφαλογραφικού σήματος (EEG) μέσα από μια καταγραφή, την ώρα που το υποκείμενο υφίσταται διαφορετικές νοητικές ασκήσεις, τυγχάνει ιδιαίτερης προσοχής. Επειδή το EEG είναι μη στάσιμο σήμα, η μελέτη χρόνου-συχνότητας είναι σημαντικό να αναλύσει τις εγκεφαλικές καταστάσεις κατά τη διάρκεια νοητικών ασκήσεων [52]. Ειδικότερα, έχει καταγραφεί ότι μεγάλης κλίμακας πρότυπα βεβαιωμένης νευρωνικής δραστηριότητας EEG εμφανίζει ποικιλία και μια σημαντική μεταβλητότητα με την πάροδο του χρόνου.

Για τον λόγο αυτό, μέχρι τώρα, η EEG ανάλυση βασίστηκε περισσότερο στην επεξεργασία στατιστικών δεδομένων, για να μπορέσει να εντοπίσει σημεία που παρουσιάζουν αξιόπιστα σταθερά χαρακτηριστικά. Η υπόθεση στην οποία βασίζονται αυτές οι στατιστικές αναλύσεις είναι η «στασιμότητα» του καταγεγραμμένου σήματος [52]. Ωστόσο στις μελέτες [52] και [129], οι πηγές EEG θεωρήθηκαν σχεδόν στάσιμες. Σε άλλη μελέτη [122] εισάγεται το εξής, το μήκος του EEG είναι τόσο μικρό, ώστε το σήμα μέσα σε αυτό μπορεί να αντιμετωπιστεί ως στάσιμο ή σχεδόν στάσιμο [96]. Ο πρωταρχικός στόχος της ερευνητικής μελέτης είναι να εξετάσει τα μήκη του σήματος που παρουσιάζουν στασιμότητα, έτσι ώστε να επιβεβαιωθεί η υπόθεση της προηγούμενης μελέτης [122]. Έτσι, για την υλοποίηση αυτή, εισάγεται μια εντελώς νέα ανάλυση του σήματος EEG.

Είναι γνωστό ότι οι πληροφορίες χρόνου-συχνότητας του EEG σήματος μπορούν να χρησιμοποιηθούν ως ένα χαρακτηριστικό για ταξινόμηση-κατηγοριοποίηση στις εφαρμογές διεπαφής εγκεφάλου-υπολογιστή (BCI - brain-computer interface) [94-103] ή για διαγνωστικούς σκοπούς [97].

Υπάρχουν δύο εναλλακτικές προσεγγίσεις για την εξέταση της στασιμότητας, η παραμετρική και η μη παραμετρική. Οι παραμετρικές μέθοδοι χρησιμοποιούνται ευρέως από όσους ασχολούνται με την έρευνα στο πεδίο του χρόνου, όπως οι οικονομολόγοι, οι οποίοι κατασκευάζουν ορισμένες υποθέσεις σχετικά με τη φύση των δεδομένων τους. Οι μη παραμετρικές προσεγγίσεις συνήθως χρησιμοποιούνται από τους ερευνητές που εργάζονται στο πεδίο της συχνότητας, όπως ηλεκτρολόγοι μηχανικοί, οι οποίοι αντιμετωπίζουν συχνά το σύστημα ως άγνωστη οντότητα και δεν μπορούν να εξάγουν οποιαδήποτε συμπεράσματα ή να εκτελέσουν υπολογισμούς με βάση τη φύση των δεδομένων.

Μη παραμετρικοί έλεγχοι δεν βασίζονται σε δεδομένα που εξάγονται από οποιαδήποτε γνώση διανέμει κανονικά κάποιος πληθυσμός. Μην έχοντας κάποια υπόθεση για τη φύση των δεδομένων, τα μη παραμετρικά τεστ είναι πιο ευρέως εφαρμόσιμα από τα παραμετρικά τεστ που συχνά απαιτούν normality των δεδομένων. Ενώ λοιπόν τα μη παραμετρικά είναι πιο ευρέως εφαρμόσιμα, έχουν το μειονέκτημα είναι ότι είναι λιγότερο ισχυρά από ότι τα παραμετρικά τεστ απλώς και μόνο επειδή οι παραδοχές στις οποίες βασίζεται η χρήση τους είναι όλο και πιο αδύναμη από τις αντίστοιχες στις οποίες βασίζονται εκείνα που σχετίζονται με παραμετρικά τεστ.

## **2.2 Συγχρονισμός Περιοδικών Ταλαντωτών**

Τα φαινόμενα συγχρονισμού αποτελούν αντικείμενο έντονης ερευνητικής προσπάθειας σε ένα ευρύ πεδίο των επιστημών. Υπάρχουν φυσικά, βιολογικά, χημικά, και κοινωνικά συστήματα με μεγάλους πληθυσμούς αλληλεπιδρώντων στοιχείων, όπου συναντούμε αυτά τα φαινόμενα. Για παράδειγμα, το φαινόμενο συγχρονισμού φάσης στο ηλεκτροεγκεφαλογράφημα (EEG), έχει χρησιμοποιηθεί ευρέως, για να παρατηρηθούν αλληλεπιδράσεις μεταξύ διαφορετικών περιοχών του εγκεφαλικού φλοιού. Οι Μαθηματικές μέθοδοι και προσεγγίσεις για φαινόμενα συγχρονισμού είναι ένα αρκετά παλιό θέμα, το οποίο ξεκίνησε πριν από σαράντα χρόνια στις πρωτοποριακές εργασίες [123]

και [57]. Υπάρχουν διάφορες προσεγγίσεις για τη μοντελοποίηση του προβλήματος του συγχρονισμού. Σε μια προσέγγιση [26], μοντελοποιείται κάθε μέλος του πληθυσμού ως ταλαντωτής φάσης. Σε αυτήν την έρευνα, ο συγχρονισμός αναλύεται με το πιο αντιπροσωπευτικό μοντέλο, το μοντέλο των συζευγμένων ταλαντωτών φάσης (coupled-phase oscillators model), γνωστό και ως μοντέλο Kuramoto. Στο [26] οι συγγραφείς παρουσιάζουν μια αυστηρή μαθηματική μέθοδο, κάποιες άλλες αριθμητικές μεθόδους και πολλές διαφορετικές παραλλαγές και επεκτάσεις του αρχικού μοντέλου, που έχουν αναπτυχθεί κατά τα τελευταία χρόνια. Υπάρχουν επίσης διάφορες εφαρμογές του μοντέλου σε πολλά διαφορετικά περιβάλλοντα.

Στο [79] οι συγγραφείς, προσδιορίζουν το συγχρονισμό στο πεδίο των βιολογικών σημάτων και πιο συγκεκριμένα στην εγκεφαλική δραστηριότητα. Οι συγγραφείς έχουν βρει μερικά αξιοπρόσεκτα patterns δραστηριότητας που παρουσιάζουν χαρακτηριστικά στασιμότητας και διάφορες λειτουργικές σχέσεις μεταξύ των διάφορων περιοχών του εγκεφάλου. Οι ερευνητές δοκιμάζουν παρόμοια σταθερά μοντέλα συσχέτισης μεταξύ πολλών διαφορετικών ασθενών και ζωνών συχνοτήτων οι οποίες διαφέρουν.

Στο [120] οι ερευνητές προτείνουν μια τεχνική για τη μέτρηση της φάσης συγχρονισμού των μη στάσιμων σημάτων από την Τιμή Ασφάλισης Φάσης (Phase Locking Value - PLV) [159] η οποία βασίζεται στο μετασχηματισμό Hilbert. Οι ερευνητές αναλύουν τον συγχρονισμό φάσης EEG σημάτων που έχουν καταγραφεί κατά τη διάρκεια κάποιων δυναμικών εργασιών με τη χρήση και της προτεινόμενης μεθόδου αλλά και μέσω της συμβατικής μεθόδου. Όσον αφορά το αποτέλεσμα της ανάλυσης, η προτεινόμενη μέθοδος φαίνεται να είναι πιο κατάλληλη από τις συμβατικές μεθόδους για την ανίχνευση του συγχρονισμού φάσης κατά τη διάρκεια δυναμικών διεργασιών.

Στο [78] οι συγγραφείς προχωρούν περισσότερο και εφαρμόζουν την έννοια του συγχρονισμού φάσης σε χαοτικά και θορυβώδη συστήματα και τη στατιστική κατανομή των σχετικών στιγμιαίων φάσεων σε ΗΕΓ, τα οποία καταγράφονται

από ασθενείς με χρόνια επιληψία λοβού. Με τη χρήση της mean phase coherence ως στατιστικό μέτρο για το συγχρονισμό φάσης, παρατήρησαν ορισμένες χαρακτηριστικές χωρικές και χρονικές μετατοπίσεις που φαίνεται να είναι στενά συνδεδεμένες με παθολογική δραστηριότητα.

Η κατανόηση των φαινομένων συγχρονισμού με τα οποία ορισμένα ταλαντούμενα στοιχεία περιορίζονται να αλληλεπιδρούν μεταξύ τους σε μια πολύπλοκη τοπολογία δικτύου είναι το κύριο θέμα που αναφέρουν οι συγγραφείς στο [6] και [44]. Επιπλέον, παρατηρούν τα χαρακτηριστικά που προκύπτουν από την αλληλεπίδραση μεταξύ της δομής και της λειτουργίας του μοτίβου διασύνδεσης. Τελικά, εξετάζουν κάποια εφαρμογή συγχρονισμού, σε πολλά πολύπλοκα δίκτυα με εφαρμογή σε διαφορετικά επιστημονικά πεδία: βιολογικά συστήματα και νευροεπιστήμες, μηχανική, πληροφορική, οικονομία και κοινωνικές επιστήμες.

Τα φαινόμενα συγχρονισμού στην περιοχή των πολύπλοκων δικτύων, ανοίγουν νέους ορίζοντες σε πολλές επιστήμες. Στο [53] ο συγγραφέας πραγματεύεται ένα θέμα το οποίο σχετίζεται με φαινόμενα του μικρόκοσμου και αποκεντρωμένων αλγόριθμων αναζήτησης. Επεξηγεί αυτό το στυλ ανάλυσης. Σε αυτήν την έρευνα υπάρχει ένα πείραμα το οποίο περιγράφει την πρώτη εμπειρική βάση για τους έξι βαθμούς του φαινομένου διαχωρισμού σε κοινωνικά δίκτυα. Επιπλέον υπάρχουν μερικά μοντέλα πιθανοτήτων δικτύων, τα οποία υποκινούνται από αυτήν την έρευνα, και εξηγεί πώς τα μοντέλα αυτά οδηγούν σε νέες αλγοριθμικές και γραφοθεωρητικές ερωτήσεις καθώς επίσης και τον τρόπο με τον οποίο υποστηρίζονται από τις πρόσφατες εμπειρικές μελέτες μεγάλων κοινωνικών δικτύων.

Σε ένα παρόμοιο ερευνητικό πεδίο [63], οι συγγραφείς προσπαθούν να δημιουργήσουν αναλυτικά εργαλεία, ώστε να μπορούν να μελετήσουν την ικανότητα να ελέγχουν ένα αυθαίρετα πολύπλοκο δίκτυο (arbitrary complex directed network), το οποίο αναγνωρίζει όλους τους κόμβους του οδηγού και το οποίο έχει μια χρονικά εξαρτώμενη διαδικασία ελέγχου, η οποία μπορεί να



ελέγξει τη δυναμική των συστημάτων. Χρησιμοποιούν αυτά τα εργαλεία σε πολλές πραγματικές περιπτώσεις δικτύων και ως αποτέλεσμα βρίσκουν ότι το σύνολο των οδηγιών προσδιορίζεται κυρίως από την κατανομή των βαθμών των δικτύων.

Τέλος, στο [117] συγγραφείς εξετάζουν ερωτήματα, όπως: ποιο είναι το τέλειο μήκος κάθε τμήματος του HEΓ σήματος που θα πρέπει να χρησιμοποιηθεί στην εκτίμηση των φαινομένων συγχρονισμού ή πώς να περιλάβουν πιο κατάλληλα το σημαντικό επίπεδο των εκτιμώμενων φαινομένων συγχρονισμού. Για να αντιμετωπίσουν αυτά τα ερωτήματα, κάνουν μια εντατική υπολογιστική μελέτη ανάλυσης φαινομένων συγχρονισμού βασισμένη σε υποκατάστατες δοκιμές με: α) ορισμένα χειροποίητα δεδομένα hand made, τα οποία παράγονται από ανάμειξη της σειράς κατάταξης, τη φασματική φάση ή τη στιγμιαία συχνότητα των αρχικών σημάτων EEG, και β) ζεύγη δια-υποκειμένων HEΓ υπό την υπόθεση ότι τα σήματα EEG διαφόρων ατόμων είναι ανεξάρτητα. Ωστόσο, μέχρι τώρα η έρευνα των φαινομένων συγχρονισμού εξαρτάται από τους ακόλουθους παράγοντες:

α) Δεν είναι εύκολο να ανιχνευθεί το επίπεδο του συγχρονισμού φάσης με βεβαιότητα, ειδικά όταν έχουν έναν μικρό αριθμό δειγμάτων «μολυσμένων» από θορύβους [106], [56], [124]. β) Σε όλες αυτές οι περιπτώσεις που εξετάστηκαν χρησιμοποιήθηκαν σήματα ίδιας συχνότητας προκειμένου να επιτευχθεί ο συγχρονισμός φάσης.

Ως εκ τούτου, πριν από τον συγχρονισμό φάσης θα πρέπει να εφαρμοστεί ο μετασχηματισμός Fourier, έτσι ώστε τα σήματα να αποσυντίθεται από μια συνάρτηση χρόνου στις συχνότητες που το συνθέτουν, και στη συνέχεια, μέσω ενός κατάλληλου φίλτρου να μπορούν να λάβουν ορισμένες συχνότητες από κάθε κανάλι. Για παράδειγμα, στην περίπτωση του EEG η μέτρηση του συγχρονισμού επιτυγχάνεται με φιλτράρισμα ρυθμού, έναν από κάθε κανάλι [117].

### 2.3 Ταξινόμηση και Κατηγοριοποίησης Δεικτών

Νευροφυσιολογικοί ή Ηλεκτροφυσιολογικοί δείκτες (ή διανυσματικοί δείκτες ή δείκτες χαρακτηριστικών διανυσμάτων, όπως συναντώνται στη βιβλιογραφία) είναι μαθηματικά παράγωγα του HEΓ σήματος και αφιλτράριστες πολυκαναλικές μετρήσεις των προκλητών δυναμικών. Επίσης χρησιμοποιούνται για την ανάλυση των δεδομένων και για την ανίχνευση διάφορων νόσων, διαταραχών και ανεπαρκειών, εξαιτίας νευροφυσιολογικών διαταραχών (κ.τ.λ. [111], [113], [119]). Τέτοιοι διανυσματικοί δείκτες, για παράδειγμα είναι, η Γενική Ισχύς Πεδίου (Global Field Power - GFP), οι Φασματικές Διαταραχές σχετικές με το γεγονός (Event Related Spectral Perturbation -ERSP), η Διασυνδεσιμότητα (InterTrial Coherence - ITC), οι εντροπίες (Shannon, Δείγματος (Sample Entropy), οι Κυματιδικές εντροπίες (Wavelet Entropy, Log energy entropy, Threshold entropy Sure entropy, Norm entropy), η Φασματική Ισχύς (Power Spectra), η τυπική απόκλιση (standard deviation), η πρώτη διαφορά σήματος (signal first difference), η κανονικοποιημένη πρώτη διαφορά (canonical signal first difference), η ασυμμετρία (skewness), η κύρτωση (kurtosis), ο συσχετισμός μεταξύ των διαφορετικών καναλιών (cross-correlation between different channels), ο κυματιδικός μετασχηματισμός (the wavelet transformation), η επικρατούσα συχνότητα (dominant frequency).

Στο [135] περιγράφεται η αναγνώριση συναισθηματικών καταστάσεων από Ηλεκτροεγκεφαλογραφικά δεδομένα, χρησιμοποιώντας διαφορετικά διανύσματα χαρακτηριστικών. Τα διανύσματα αυτά δείχνουν τη συναισθηματική κατάσταση των υποκειμένων τη στιγμή του πειράματος. Φυσικά το συναίσθημα έχει άμεση σχέση με μαθησιακές δυσκολίες, όπως για παράδειγμα το άγχος το οποίο μπορεί να αποδειχθεί τροχοπέδη στην Εκπαιδευτική Διαδικασία [146] [134]. Τα διανύσματα αυτά είναι η μέση τιμή, η τυπική απόκλιση, η πρώτη διαφορά σημάτων, η πρώτη διαφορά των κανονικοποιημένων σημάτων, λοξότητα, κύρτωση, ετεροσυσχέτιση μεταξύ των διαφορετικών καναλιών, ο κυματιδικός μετασχηματισμός και η επικρατέστερη

συχνότητα. Τα αποτελέσματα αυτά μελετώνται μέσω ταξινομητών. Επίσης στο [132] γίνεται μελέτη ταξινόμησης βιοσημάτων για διαχωρισμό συναισθημάτων. Σε αυτό οι συγγραφείς μελετούν νευροφυσιολογικούς δείκτες, όπως τα ERPs (Event Related Potentials) και τα EROs (Event Related Oscillations), ERS (Event Related Synchronization) και ERDs (Event Related Desynchronization).

Στο [131] οι συγγραφείς μελετούν στατιστικά τις διαφορετικές κορυφώσεις που παρατηρούνται στα υποκείμενα κατά τη διάρκεια αντιμετώπισης μαθησιακών δυσκολιών. Τα ηλεκτροεγκεφαλικά δεδομένα σε αυτήν την εργασία προέρχονται από άτομα με επιληψία. Από την ανάλυση αυτών των σημάτων προσδιορίστηκαν παράμετροι (συγκεκριμένες κορυφώσεις) που διαφοροποιούν στατιστικά τα άτομα με μαθησιακές δυσκολίες σε σχέση με τους υγιείς. Παράλληλα, εξετάστηκαν παράμετροι από την κλασική θεωρία βιοσημάτων, όπως η ενέργεια και οι χαρακτηριστικοί ρυθμοί. Τέλος, επιλύθηκε το αντίστροφο πρόβλημα της ηλεκτροεγκεφαλογραφίας, ώστε να βρεθούν οι ρευματικές πηγές που προκαλούν τα αντίστοιχα σήματα στην επιφάνεια του κεφαλιού. Από τις πηγές αυτές επιδιώχθηκε ο προσδιορισμός περιοχών του εγκεφάλου που πιθανώς να είναι υπεύθυνες για την εμφάνιση μαθησιακών δυσκολιών.

Στο [36] αναφέρεται σε διαφοροποίηση των σημάτων κατά τη διάρκεια αναγνώρισης εικόνων. Κύριο θέμα αυτής της εργασίας είναι η οπτικοποίηση των εγκεφαλικών δυναμικών, αλλά ταυτόχρονα γίνεται αναφορά στη διαφοροποίηση των δυναμικών ανάμεσα στα σήματα που παράγονται, όταν το υποκείμενο προσπαθεί να αναγνωρίσει μια εύκολη από μια δύσκολη εικόνα. Η διαφοροποίηση που παρατηρείται στην εγκεφαλική δραστηριότητα γίνεται οπτικά από το grand average figure 1 που υπάρχει στη σελίδα 2 της μελέτης. Δε χρησιμοποιούν κάποια μέθοδο για ταξινόμηση ούτε κάποιο μαθηματικό μοντέλο, παρά απλή οπτική διερεύνηση. Επίσης γίνεται προσπάθεια αποσαφήνισης της διαφοράς από τα δεδομένα του πίνακα 1 στη σελίδα 4, στους οποίους παρουσιάζονται οι χρόνοι αντίδρασης.

Στο [121] οι συγγραφείς αξιολογούν τη δυνατότητα του δείκτη φασματικής ισχύος (power spectrum) της εγκεφαλικής ηλεκτρικής δραστηριότητας να δώσει

διαφορές (διάκριση) ανάμεσα σε άτομα τα οποία είναι κανονικά και σε άλλα που έχουν μαθησιακές δυσκολίες. Ένας άλλος στόχος της συγκεκριμένης έρευνας είναι να συσχετίσει αυτήν την ηλεκτρική δραστηριότητα με την ευφυΐα, τη σχολική δραστηριότητα και τη νευροφυσιολογική απόδοση από διάφορες δοκιμασίες. Η μέθοδοι που χρησιμοποιούν είναι κλασσικές μέθοδοι ανάλυσης σημάτων, όπως το cross validation, ή το cross correlation 10 μεταβλητών και οι discrimination functions. Η ταξινόμηση έγινε με ανεξάρτητους ταξινομητές, όπως replication LD. Επίσης έγινε correlation ανάμεσα σε συμπεριφορικές μεταβλητές (behavioral variables), όπως η Wide range Achievement. Εκτελέστηκαν αρκετά Tests και WISC-R sub-tests και electrophysiology. Μελετήθηκαν 19 κανάλια.

Υπάρχουν κάποιες εργασίες, όπου οι ερευνητές χρησιμοποιούν Νευροφυσιολογικούς δείκτες, προκειμένου να προσδιοριστούν συναισθηματικές καταστάσεις. Στο [93] οι συγγραφείς περιγράφουν την αναγνώριση συναισθηματικής κατάστασης χρησιμοποιώντας ηλεκτροεγκεφαλογραφικά (EEG) σήματα, με τη βοήθεια διαφορετικών δεικτών σε μορφή διανύσματος. Αυτά τα διανύσματα δείχνουν την συναισθηματική κατάσταση των ατόμων που συμμετέχουν κατά τη στιγμή της λήψης του EEG.

Προφανώς, το συναίσθημα έχει στενή σχέση με μαθησιακές δυσκολίες, για παράδειγμα μαθηματικό, αριθμητικό ή γενικότερα εκπαιδευτικό άγχος. Το συμπέρασμα είναι ότι το άγχος είναι ένα συναίσθημα που μπορεί να είναι σοβαρό πρόβλημα στην εκπαιδευτική διαδικασία [68].

Τα αποτελέσματα αξιολογούνται με ταξινόμηση-κατηγοριοποίηση. Επίσης υπάρχει μια μελέτη σχετικά με την κατηγοριοποίηση των βιοσημάτων στο [107]. Εκεί οι συγγραφείς μελετούν νευροφυσιολογικούς δείκτες, όπως τα ERPs (Δυναμικά Οδηγούμενα από το Γεγονός - Event Related Potentials), τα EROs (Ταλαντώσεις Οδηγούμενες από το Γεγονός - Event Related Oscillations), ERS (Συγχρονισμός Οδηγούμενος από το Γεγονός - Event Related Synchronization) και ERDs (Αποσυγχρονισμός Οδηγούμενος από το Γεγονός - Event Related Desynchronization). Στο [41] οι συγγραφείς μελετούν στατιστικά διαφορετικές

κορυφές που παρατηρούνται σε άτομα κατά τη διάρκεια μιας διαδικασίας που αντιμετωπίζουν μαθησιακές δυσκολίες. Τα ηλεκτροεγκεφαλογραφικά δεδομένα στην έρευνα αυτή λήφθηκαν από άτομα που πάσχουν από επιληψία. Μετά την ανάλυση του σήματος, υπήρχαν παράμετροι (συγκεκριμένες κορυφές) που αναγνωρίστηκαν, οι οποίες διαφοροποιούν στατιστικά τα άτομα με μαθησιακές δυσκολίες από τα φυσιολογικά άτομα. Παράλληλα εξετάστηκαν άλλες παράμετροι από την κλασσική θεωρία βιοσημάτων, όπως η ενέργεια κ.τ.λ.. Τέλος, στην ίδια έρευνα επιλύθηκε το αντίστροφο ηλεκτροεγκεφαλογραφικό πρόβλημα, έτσι ώστε να μπορούν να υπάρξουν ρευματικές πηγές, που προκαλούν τα αντίστοιχα σήματα στην επιφάνεια του κεφαλιού. Μετά τη μελέτη αυτών των πηγών, οι συγγραφείς αναφέρουν ότι έχουν ως στόχο να προσδιορίσουν τις περιοχές του εγκεφάλου που πιθανώς να είναι υπεύθυνες για την εμφάνιση μαθησιακών δυσκολιών.

Στο [36] οι συγγραφείς αναφέρονται στη διαφοροποίηση των σημάτων κατά τη διάρκεια της αναγνώρισης εικόνας. Το βασικό θέμα αυτής της έρευνας δεν είναι μόνο η οπτικοποίηση των δυναμικών του εγκεφάλου, αλλά επίσης η διαφοροποίηση των δυναμικών μεταξύ των σημάτων που παράγονται, όταν το υποκείμενο προσπαθεί να διακρίνει μια «εύκολη» εικόνα από μια «δύσκολη». Αυτή η διαφοροποίηση που παρατηρείται κατά τη δραστηριότητα του εγκεφάλου οπτικοποιείται από το μεγάλο μέσο όρο [36] - σχήμα 1, σελίδα 2). Οι συγγραφείς δεν χρησιμοποιούν ούτε κάποια μέθοδο ταξινόμησης αλλά ούτε και κάποιο συγκεκριμένο μαθηματικό μοντέλο. Κάνουν μόνο μια οπτική εξερεύνηση. Υπάρχει επίσης μια προσπάθεια που γίνεται προκειμένου να αποσαφηνιστεί η διαφοροποίηση των χρόνων αντίδρασης των υποκειμένων στα ερεθίσματα, οι οποίοι καταγράφονται στην εργασία.

Στο [121] οι συγγραφείς αξιολογούν την πιθανότητα η φασματική ισχύς της ηλεκτρικής δραστηριότητας του εγκεφαλικού φλοιού να εμφανίζει διαφορά μεταξύ ατόμων που έχουν φυσιολογική αντιληπτική ικανότητα και άλλων ατόμων που έχουν μαθησιακές δυσκολίες. Ένας άλλος στόχος αυτής της ειδικής έρευνας είναι η συσχέτιση αυτής της ηλεκτρικής δραστηριότητας με την


ευστροφία. Επίσης συσχετίζεται με τη σχολική δραστηριότητα και την έξοδο που παράγεται από διάφορα νευροφυσιολογικά tests. Οι μέθοδοι που χρησιμοποιούνται είναι οι κλασικές μέθοδοι ανάλυσης σήματος, όπως cross validation και cross correlation των 10 μεταβλητών και οι discriminant functions. Η ταξινόμηση έγινε με διάφορους ανεξάρτητους ταξινομητές, όπως ο replication LD. Υπήρξε επίσης συσχέτιση μεταξύ των μεταβλητών συμπεριφοράς (behavioral variables), όπως Wide Range Achievement.

## **2.4 Βασικά στοιχεία Νευροφυσιολογίας του Εγκεφάλου**

Νευροφυσιολογία του Εγκεφάλου [1], [29], [49], [50], [51], [67] είναι το τμήμα της φυσιολογίας που ασχολείται με τη μελέτη της λειτουργίας των νευρών και του νευρικού συστήματος του Εγκεφάλου. Χωρίς να θέλουμε να διεισδύσουμε σε ειδικά ανατομικά στοιχεία και εξειδικευμένα στοιχεία φυσιολογίας, θα αναφέρουμε μερικά στοιχεία από τη δομή και τη λειτουργία των νευρών του ανθρώπινου εγκεφάλου :

### **2.4.1 Μετάδοση Νευρικού Ερεθίσματος**


Το ανθρώπινο εγκεφαλικό νευρικό κύτταρο (ή αλλιώς Νευρώνας – nerve cell or neuron -**Εικόνα 2**) αποτελείται από το σώμα (cell body – soma), τους δενδρίτες (dendrites), τον άξονα (axon), και τις αξονικές απολήξεις (axon terminals).



Εικόνα 2: Ανθρώπινο Εγκεφαλικό Νεύρο ή Νευρώνας  
(public domain image, free to use, share or modify, even commercially)

Νευρώνας είναι [50],[51],[137] ένα κύτταρο το οποίο είναι υπεύθυνο για τη διαβίβαση σημάτων (ή πληροφοριών) οι οποίες είναι γνωστές ως «νευρικές ώσεις». Τα νευρικά κύτταρα δέχονται και διαβιβάζουν νευρικές ώσεις, δηλαδή ανταλλάσσουν μεταξύ τους πληροφορίες. Ένας εγκέφαλος περιέχει κατά τη γέννησή του περισσότερα από εκατό δισεκατομμύρια νευρώνες, οι οποίοι ελαττώνονται αργά με την πάροδο της ηλικίας. Κάθε νευρώνας αποτελείται από το κυτταρικό σώμα και τις αποφυάδες. Οι αποφυάδες διακρίνονται στους δενδρίτες, που λαμβάνουν σήματα (πληροφορίες) από άλλους νευρώνες και τον νευράξονα, ο οποίος έχει συνήθως μεγάλο μήκος και στέλνει σήματα σε άλλα νευρικά κύτταρα και μυς. Ο νευράξονας επικοινωνεί με τα άλλα κύτταρα μέσω των απολήξεών του, οι οποίες ονομάζονται τελικά κομβία, με ειδικές επαφές, τις συνάψεις (**Εικόνα 3**). Τα νεύρα επικοινωνούν μεταξύ τους με ηλεκτρικά σήματα τα οποία περνούν από τις απολήξεις στους δενδρίτες μέσω των ηλεκτρικών συνάψεων. Όταν τα σήματα φτάσουν στα τελικά κομβία, πυροδοτούν την απελευθέρωση χημικών διαβιβαστών (ή νευροδιαβιβαστών), οι οποίοι είναι αποθηκευμένοι σε κυστίδια [49]. Οι χημικοί διαβιβαστές δεσμεύονται σε μόρια-υποδοχείς, που υπάρχουν στην επιφάνεια των μετασυναπτικών κυττάρων. Ένας

συνήθης νευρώνας σχηματίζει χίλιες περίπου συνάψεις και δέχεται ακόμα περισσότερες. Οι αριθμοί αυτοί ποικίλλουν σημαντικά ανάλογα με την περιοχή του εγκεφάλου και τον τύπο του νευρώνα. Οι συνάψεις διεγείρουν ή καταστέλλουν τη λειτουργία άλλων νευρικών κυττάρων, σε μια αλληλουχία μεγάλης πολυπλοκότητας.




Εικόνα 3: Απολείξεις, Δενδρίτες και Συνάψεις  
(public domain image, free to use, share or modify, even commercially)

Όταν ένας νευροδιαβιβαστής αντιδράσει χημικά με ειδικές πρωτεΐνες που βρίσκονται στους υποδοχείς του νευρικού ερεθίσματος, δηλαδή τους δενδρίτες του νευρικού κυττάρου-υποδοχέα του νευρικού ερεθίσματος, προκαλεί μια σειρά μεταβολών στη μετασυναπτική μεμβράνη, οι οποίες εν συντομία είναι οι εξής [50], [51], [67] :

Οι δενδρίτες του νευρικού κυττάρου-υποδοχέα του ερεθίσματος δέχονται το ερέθισμα και ανοίγουν τα κανάλια του  $\text{Na}^+$ . Για να οδηγήσει σε εξέλιξη της διαδικασίας το παραπάνω ερέθισμα, πρέπει το δυναμικό δράσης να είναι από τα



-70mV έως τα -50mV (Εικόνα 4). Από την στιγμή που το δυναμικό δράσης φτάσει το κατώφλι δράσης, τότε επιπλέον κανάλια  $\text{Na}^+$  ανοίγουν, μέχρι το δυναμικό δράσης να φτάσει τα +30mV. Αυτή η διαδικασία ονομάζεται αποπόλωση. Τότε κλείνουν τα κανάλια του  $\text{Na}^+$  και ανοίγουν τα κανάλια του  $\text{K}^+$ . Από τη στιγμή που τα κανάλια του  $\text{K}^+$  ανοίγουν πολύ πιο αργά η αποπόλωση έχει χρόνο να πραγματοποιηθεί. Έχοντας και τα δύο κανάλια ιόντων ανοιχτά την ίδια χρονική στιγμή, το σύστημα θα τείνει στην ουδετερότητα και έτσι θα αποτραπεί η δημιουργία δυναμικού δράσης.



Εικόνα 4: Δυναμικό Δράσης – Πόλωση Εκπόλωση Νευρικού Κυτάρρου

Έχοντας τα κανάλια του  $\text{K}^+$  ανοιχτά, η μεμβράνη ξεκινάει την επαναπόλωση για να φτάσει στο δυναμικό ηρεμίας. Η επαναπόλωση ουσιαστικά ξεπερνάει το δυναμικό ηρεμίας και φτάνει περίπου τα 100mV. Αυτό ονομάζεται υπερπόλωση και είναι παρά πολύ χρήσιμο στη μετάδοση της πληροφορίας. Η υπερπόλωση εμποδίζει τον νευρώνα να λάβει άλλο ερέθισμα την ίδια χρονική στιγμή, ή τουλάχιστον ανεβάζει το κατώφλι για οποιοδήποτε νέο ερέθισμα. Μια ακόμα σημαντική ιδιότητα της υπερπόλωσης είναι η ικανότητά της να διασφαλίζει τη μετάδοση του σήματος προς μία μόνο κατεύθυνση. Μετά την υπερπόλωση οι αντλίες  $\text{Na}^+/\text{K}^+$  φέρνουν την μεμβράνη στην κατάσταση ηρεμίας των -70 mV και πλέον το ερέθισμα έχει διαδοθεί.

#### **2.4.2 Καταγραφή και ανάλυση βιολογικών σημάτων**

Τα βιολογικά σήματα είναι χωρικές, χρονικές, ή χωροχρονικές καταγραφές ενός βιολογικού γεγονότος, όπως μια ιδέα ή σκέψη στον εγκέφαλο, μια παλλόμενη καρδιά ή ένας συσπώμενος μυς.

Η ηλεκτρική, χημική, και μηχανική δραστηριότητα που εμφανίζεται κατά τη διάρκεια αυτού του βιολογικού γεγονότος παράγει συχνά σήματα που μπορούν να μετρηθούν και να αναλυθούν. Τα βιολογικά σήματα, επομένως, περιέχουν τις πληροφορίες που μπορούν να χρησιμοποιηθούν, για να εξηγήσουν τους φυσιολογικούς μηχανισμούς που υποκρύπτονται σε ένα συγκεκριμένο βιολογικό γεγονός ή ένα σύστημα.

Τα βιοσήματα μπορούν να αποκτηθούν με ποικίλους τρόπους, π.χ., από το σκουφάκι με τα ηλεκτρόδια που χρησιμοποιούνται, για να συλλάβουν τα ηλεκτρικά σήματα του εγκεφάλου (εγκεφαλογράφημα), ή από το στηθοσκόπιο που χρησιμοποιεί ο γιατρός, για να ακούσει τον ήχο της καρδιάς ενός ασθενή (καρδιογράφημα) ή με τη χρήση των ιδιαίτερα σύνθετων και τεχνολογικά προηγμένων βιοϊατρικών οργάνων.

Στις περισσότερες περιπτώσεις, δεν αρκεί απλά η απόκτηση ενός βιολογικού σήματος. Πρέπει να αναλυθούν, για να ανακτηθούν πιο σχετικές πληροφορίες από αυτά. Οι βασικές μέθοδοι ανάλυσης σημάτων, π.χ. ενίσχυσης, φιλτραρίσματος, ψηφιοποίησης, επεξεργασίας και αποθήκευσης, μπορούν να εφαρμοστούν σε πολλά βιολογικά σήματα. Αυτές οι τεχνικές ολοκληρώνονται γενικά με τη χρησιμοποίηση των ψηφιακών υπολογιστών. Επιπρόσθετα σε αυτές τις γνωστές διαδικασίες έχουν αναπτυχθεί διαφορετικές ψηφιακές μέθοδοι για την ανάλυση των βιολογικών σημάτων. Σε αυτές περιλαμβάνονται ο υπολογισμός μέσου όρου σημάτων, η ανάλυση κυματιδίων και οι τεχνικές τεχνητής νοημοσύνης.

## 2.5 Στοιχεία ηλεκτροεγκεφαλογραφήματος

Το ηλεκτροεγκεφαλογράφημα (HEΓ) αποτελεί καταγραφή του ηλεκτρικού πεδίου του ανθρώπινου εγκεφάλου. Είναι ένα βιοσήμα. Το HEΓ βασίζεται στην καταγραφή διαφορών δυναμικού του φλοιού του εγκεφάλου. Αυτές οι διαφορές δυναμικού παρουσιάζονται στο τριχωτό της κεφαλής, ως αποτέλεσμα της λειτουργίας του εγκεφάλου. Τα δυναμικά αυτά αντιστοιχούν σε ηλεκτρικά σήματα χαμηλού πλάτους της τάξης μερικών mV (1-100 mV). Συνεπώς τα σήματα είναι ασθενή και έτσι για τη σωστότερη απεικόνιση απαιτείται ενίσχυση των σημάτων καθώς και πυκνότερη κάλυψη του κεφαλιού με (απαγωγά) ηλεκτρόδια.


Η μέτρηση λοιπόν των διαφορών δυναμικού γίνεται [134] με ηλεκτρόδια τα οποία τοποθετούνται σε διάφορες θέσεις επάνω στο κεφάλι. Τα ηλεκτρόδια (απαγωγές), είναι οι αισθητήρες του συστήματος, οι οποίοι μετατρέπουν το ρεύμα ιόντων μέσα στο ανθρώπινο σώμα σε ρεύμα ηλεκτρονίων μέσα στα καλώδια, τα οποία μετά οδηγούν αυτό το ρεύμα σε επόμενα στάδια επεξεργασίας. Η επαφή τους με το δέρμα γίνεται μέσω μιας κολλώδους ουσίας ή μέσω ενός μικρού δακτυλιδιού, που από τη μια μεριά προσκολλάται στο δέρμα και από την άλλη στο κυρίως ηλεκτρόδιο. Για να επιτευχθεί χαμηλή αντίσταση επαφής, χρησιμοποιείται συνήθως οινόπνευμα στο σημείο όπου το ηλεκτρόδιο έρχεται σε επαφή με το δέρμα. Από το σημείο αυτό κινούνται ιόντα, μέχρι να επέλθει ισορροπία. Η ισορροπία αυτή είναι συνάρτηση της ιοντικής συγκέντρωσης που υπάρχει στις δύο πλευρές του συνόρου.

Όταν στον εγκέφαλο υπάρξει κάποια ενέργεια-διαδικασία η οποία τον ενεργοποιεί, δημιουργούνται ηλεκτρικά σήματα, τα οποία στην πραγματικότητα είναι ροή ιόντων, και έτσι δημιουργείται μεταβολή της ιοντικής συγκέντρωσης και κατά συνέπεια αναπτύσσεται διαφορά δυναμικού μεταξύ των σημείων επαφής του ηλεκτροδίου με το δέρμα. Έτσι υπάρχει ηλεκτρικό ρεύμα το οποίο καταγράφεται τελικά από το ηλεκτρόδιο. Η κυματομορφή που παράγεται από την καταγραφή είναι το εγκεφαλογράφημα (HEΓ).

Η χρήση του ΗΕΓ στη Νευρολογία είναι ευρύτατη, καθώς αποτελεί μέθοδο φθηνή, ανώδυνη και απλή στην εφαρμογή της. Από τη μελέτη του ΗΕΓ μπορούν να εξαχθούν ιδιαίτερα χρήσιμα συμπεράσματα για τη σωστή εξέλιξη του Κεντρικού Νευρικού Συστήματος ενός ανθρώπου, από τη γέννηση του έως την ενηλικίωση. Επίσης το ΗΕΓ μπορεί να δώσει χρήσιμα στοιχεία στην περίπτωση εγκεφαλοπαθειών (π.χ. νόσο Alzheimer) [29], [46] ή για την περίπτωση επιληψίας τόσο για τη βαρύτητα της νόσου όσο και για την υποβοήθηση της διάγνωσης και της πρόγνωσης. Το ΗΕΓ μελετάται ακόμη στις περιπτώσεις κρανιοεγκεφαλικών κακώσεων, κώματος και αποτελεί βασικό εργαλείο για τη μελέτη του ύπνου.

### **2.5.1 Συστήματα τοποθέτησης καλωδίων**

Τα ηλεκτρόδια τοποθετούνται επάνω στο κεφάλι βάσει διάφορων προτύπων [110][1]. Το δημοφιλέστερο είναι το «Διεθνές Σύστημα Τοποθέτησης Ηλεκτροδίων 10-20» (10-20 International System of Electrode Placement) ή «Διεθνές Σύστημα 10-20» (Εικόνα 5), το οποίο επινοήθηκε από τον Herbert H. Jasper το 1958 και έχει υιοθετεί από την Παγκόσμια Ομοσπονδία Ηλεκτροεγκεφαλογραφίας και Κλινικής Νευροφυσιολογίας.



Εικόνα 5: Το Διεθνές Σύστημα 10-20  
(public domain image, free to use, share or modify, even commercially)

Η ονομασία του συστήματος οφείλεται στην επιλογή του 20% της αποστάσεως μεταξύ των δύο αυτιών ως την απόσταση ανάμεσα σε δύο οποιαδήποτε ηλεκτρόδια και στην επιλογή του 10% της αποστάσεως μεταξύ των δύο αυτιών ως την απόσταση από το αυτί στο κοντινότερο προς αυτό ηλεκτρόδιό του (ή του 10% της αποστάσεως μεταξύ του ριζορρινίου και του ινίου ως την απόσταση από το ριζορρίνιο ή το ίνιο μέχρι στο κοντινότερο προς αυτό ηλεκτρόδιό του - το ριζορρίνιο (nasion), το οποίο είναι το σημείο μεταξύ του μετώπου και της μύτης ανάμεσα στα μάτια, και το ίνιο (inion), που είναι το χαμηλότερο σημείο του κρανίου στο πίσω μέρος του) [1], [110].

Επιπρόσθετα, ηλεκτρόδια (απαγωγές) τοποθετούνται στους λοβούς των αυτιών καθώς και σε θέσεις κοντά στα μάτια. Οι απαγωγές στους λοβούς των αυτιών χρησιμοποιούνται, γιατί τα μετρούμενα Προκλητά Δυναμικά σε ένα σημείο της δερματικής επιφάνειας του κρανίου υπολογίζονται ως η διαφορά δυναμικού

μεταξύ του σημείου αυτού και των λοβών, οι οποίοι εξ' αιτίας του γεγονότος ότι διαπερνώνται από μικρό αριθμό νευρών και έχουν χαμηλή αιμάτωση, εμφανίζουν ιδιαίτερα σταθερό και χαμηλό δυναμικό.

Μέχρι σήμερα έχουν προταθεί διάφορες επεκτάσεις [1], [110] του μοντέλου 10-20, όπως το μοντέλο 10-10 και το μοντέλο 10-5, στις οποίες παρεμβάλλονται ηλεκτρόδια ανάμεσα στις θέσεις του συστήματος 10-20. Οι προεκτάσεις αυτές γίνονται, με σκοπό να αυξηθεί ο αριθμός των παρεχόμενων καναλιών. Το μοντέλο που έχει γίνει αποδεκτό και έχει τεκμηριωθεί από την Αμερικανική Ηλεκτροεγκεφαλογραφική Κοινότητα (American Electroencephalographic Society) είναι το 10-10 το οποίο χρησιμοποιείται ευρέως σήμερα. Το μοντέλο 10-5, αν και είναι υποσχόμενο, βρίσκεται ακόμα σε πειραματικά στάδια.

### **2.5.2 Ονοματολογία ηλεκτροδίων**

Η ονομασία των ηλεκτροδίων σχετίζεται με τον λοβό και το ημισφαίριο στο οποίο τοποθετούνται (*Εικόνα 5*).

Τα γράμματα F, Fr, T, C, P και O αντιστοιχούν σε Frontal (Μετωπιαίος), Frontal pole (Μετωπιαίος πόλος), Temporal (Κροταφικός), Central (Κεντρικός), Parietal (Βρεγματικός) και Occipital (Ινιακός) αντίστοιχα [1], [46], [110], [148].

Στην πραγματικότητα, δεν υπάρχει Κεντρικός Λοβός, το γράμμα "C" χρησιμοποιείται για λόγους προσδιορισμού της θέσης. Χρησιμοποιείται επίσης το γράμμα "z" (zero – μηδέν), το οποίο αναφέρεται σε ηλεκτρόδια που τοποθετούνται στη μέση γραμμή.


Οι άρτιοι αριθμοί (2, 4, 6, 8) αναφέρονται σε θέσεις των ηλεκτροδίων στο δεξιό ημισφαίριο, ενώ οι περιττοί αριθμοί (1, 3, 5, 7), αναφέρονται σε θέσεις στο αριστερό ημισφαίριο.

Στα 21 βασικά ηλεκτρόδια του συστήματος του H. Jasper μπορούν να προστεθούν και «δευτερεύοντα» ηλεκτρόδια, τα οποία έχουν επίσης τυποποιημένες θέσεις [148].

Το «Εκτεταμένο Διεθνές Σύστημα Τοποθέτησης Ηλεκτροδίων 10-20» [46][148] (Extended 10-20 International System of Electrode Placement) ή «Σύστημα 10-10», το οποίο βασίστηκε σε μια πρόταση των G. E. Chatrian, E. Lettich, P. L. Nelson και εκδόθηκε από την AES (American Electroencephalographic Society), υποδεικνύει τις θέσεις 54 «δευτερευόντων» ηλεκτροδίων (συνολικά 75 ηλεκτροδίων).

### 2.5.3 Μοντάζ

Η σειρά με την οποία τα ηλεκτρόδια καταγράφουν τις διαφορές δυναμικού στο τριχωτό της κεφαλής ονομάζεται μοντάζ [76]. Στην εικόνα μπορούμε να δούμε διαφόρων ειδών μοντάζ.



Εικόνα 6: Διάφορα μοντάζ  
(public domain image, free to use, share or modify, even commercially)

Η καταγραφή μπορεί να γίνει με δύο τρόπους. Ο πρώτος τρόπος είναι να μετρήσουμε τη διαφορά δυναμικού κάθε ηλεκτροδίου ως προς ένα σταθερό και εγκεφαλικά ουδέτερο σημείο (π.χ. μύτη, αυτιά κ.ά.). Αυτός ο τρόπος μέτρησης ονομάζεται μονοπολικός ή με Αναφορά. Σε αντίθεση με αυτόν τον τρόπο, ο διπολικός τρόπος καταγραφής μετράει τη διαφορά δυναμικού ενός ηλεκτροδίου


ως προς ένα άλλο ηλεκτρόδιο, συνήθως το επόμενο του. Τα διπολικά μοντάζ είναι ιδιαιτέρως χρήσιμα για την οπτική ανάλυση της εστιακής εγκεφαλικής δραστηριότητας, όπως είναι οι αιχμές (spikes), αιχμηρά κύματα (sharp waves). Υπάρχουν επίσης τεχνικές οι οποίες δεν χρησιμοποιούν κάποιο συγκεκριμένο ηλεκτρόδιο ως αναφορά, όπως π.χ. το μοντάζ της μέσης κοινής αναφοράς (Common Average Reference – C.A.R.), σύμφωνα με το οποίο [134] κάθε ηλεκτρόδιο έχει ως σημείο αναφοράς τον μέσο όρο όλων των σημάτων. Το θεωρητικό υπόβαθρο του συγκεκριμένου μοντάζ έγκειται στο γεγονός ότι το ανθρώπινο κεφάλι το θεωρούμε ως μια ομογενή και ομοιόμορφη σφαίρα. Στην ιδανική περίπτωση που τα ηλεκτρόδια τοποθετηθούν συμμετρικά πάνω στο τριχωτό της κεφαλής, τότε αυτά θα μας δώσουν μηδενικό μέσο όρο. Αυτό συμβαίνει, γιατί τα δίπολα που παράγουν ένα σήμα σε κάποιο συγκεκριμένο ηλεκτρόδιο θα μας παράγουν το ακριβώς αντίθετο σήμα στο αντισυμμετρικό του ηλεκτρόδιο .

Στα πειράματα των οποίων τις καταγραφές χρησιμοποιήσαμε στη συγκεκριμένη εργασία χρησιμοποιήθηκε το μοντάζ με αναφορά (για μια πλήρη περιγραφή των πειραμάτων δες την παράγραφο 0).

#### **2.5.4 Εγκεφαλικοί Ρυθμοί**


Τα σήματα που προκύπτουν από την καταγραφή των διαφορών δυναμικού, όπως είδαμε, αποτελούν το εγκεφαλογράφημα και έχουν τη μορφή αυτών της *Εικόνα 7*. Οι κυματομορφές αυτές εμπεριέχουν Εγκεφαλικούς Ρυθμούς (δες *Εικόνα 8* έως *Εικόνα 12*) των οποίων το κύριο χαρακτηριστικό τους είναι οι συχνότητες των αρμονικών από τις οποίες αποτελούνται δηλαδή το φασματικό τους περιεχόμενο. Το εύρος των συχνοτήτων που περιέχονται σε ένα ηλεκτροεγκεφαλογράφημα εκτείνεται από 0,1Hz μέχρι 70Hz. Οι κυριότεροι ρυθμοί είναι οι άλφα, βήτα, θήτα και δέλτα, οι συχνότητες και τα συνήθη πλάτη των οποίων φαίνονται στον *Πίνακας 1* [29], [46], [76].






Εικόνα 7: Ηλεκτροεγκεφαλογράφημα με Εγκεφαλικούς Ρυθμούς  
(public domain image, free to use, share or modify, even commercially)

Ο ρυθμός άλφα εμφανίζεται [29], [46], [76], [130] σε φυσιολογικά και ήρεμα άτομα, τα οποία ησυχάζουν με τα μάτια κλειστά. Η συχνότητές τους είναι γύρω στα 10 Hz στους ενήλικες (στα παιδιά μέχρι 12 χρόνων είναι περίπου 8,5 Hz) με τη μέγιστη τάση να παρουσιάζεται στα ινιακά ηλεκτρόδια (occipital electrodes), O1 and O2. Πήρε το όνομα α, επειδή είναι ο πρώτος ρυθμός που μελετήθηκε. Η μείωση του συγκεκριμένου ρυθμού μπορεί να σημαίνει πνευματική δραστηριότητα αλλά και πιθανή ανωμαλία και πιθανές δομικές βλάβες, όταν εμφανίζονται σε παιδιά. Μη φυσιολογική θεωρείται η εγκεφαλική δραστηριότητα σε σχέση με το ρυθμό άλφα, όταν εμφανίζεται διάχυτα και δεν ανταποκρίνεται σε εξωτερικό ερέθισμα. Η κατάσταση αυτή ονομάζεται «Άλφα Κώμα» (οι εικόνες των εγκεφαλικών ρυθμών είναι από το [Brainwave images © Hugo Gamboa Dez 2005] κάτω από την άδεια GNU/GPL ).




Εικόνα 8: Ρυθμός Άλφα - Άδεια δημοσίευσης GNU/GPL - Brainwave images © Hugo Gamboa Dez 2005 ([https://commons.wikimedia.org/wiki/File:Eeg\\_alpha.svg](https://commons.wikimedia.org/wiki/File:Eeg_alpha.svg))

Ο ρυθμός βήτα [29], [46], [76], [130] έχει συχνότητες πάνω από 13 Hz και εμφανίζεται σε όλα τα άτομα, αλλά είναι συνήθως χαμηλού πλάτους και συχνά παραβλέπεται, ειδικά όταν το αντικείμενο είναι μεταξύ υπνηλίας και εγρήγορσης. Βήτα ρυθμό συναντάμε σε άτομα που είναι σε εγρήγορση και έχουν την προσοχή τους στραμμένη σε εξωτερικά ερεθίσματα ή καταβάλλουν συγκεκριμένη πνευματική προσπάθεια. Ο ρυθμός βήτα διαμοιράζεται μεταξύ εμπρόσθιας και κεντρικής περιοχής του εγκεφαλικού φλοιού. Η μη ομαλή εμφάνιση του ρυθμού β συνδέεται με τα ναρκωτικά.




Εικόνα 9: Ρυθμός Βήτα - Άδεια δημοσίευσης GNU/GPL - Brainwave images © Hugo Gamboa Dez 2005 ([https://commons.wikimedia.org/wiki/File:Eeg\\_beta.svg](https://commons.wikimedia.org/wiki/File:Eeg_beta.svg))

Ο ρυθμός θήτα [29], [46], [76], [130] είναι εγκεφαλική δραστηριότητα με συχνότητες ανάμεσα στα 4 Hz και 8 Hz και παρατηρείται στη φάση της υπνηλίας αλλά και του ύπνου στους ενήλικες. Επίσης συχετίζεται με μηχανισμούς καταστολής. Τα μικρά παιδιά εμφανίζουν ρυθμό θήτα κατά τη διάρκεια του βαδίσματος, πράγμα το οποίο καθιστά την καταγραφή του εγκεφαλογραφήματος ιδιαίτερα δύσκολη. Ο ρυθμός θήτα έχει συνδυαστεί και με καταστάσεις βαθιάς χαλάρωσης και διαλογισμού. Μη φυσιολογική εμφάνιση του ρυθμού θ μπορεί να σημαίνει βλάβη σε δομική λειτουργία του εγκεφάλου.




Εικόνα 10: Ρυθμός Θήτα - Άδεια δημοσίευσης GNU/GPL - Brainwave images © Hugo Gamboa Dez 2005 ([https://commons.wikimedia.org/wiki/File:Eeg\\_theta.svg](https://commons.wikimedia.org/wiki/File:Eeg_theta.svg))

Ο ρυθμός δέλτα [29], [46], [76], [130] είναι εγκεφαλική δραστηριότητα με συχνότητες ανάμεσα στο 0.5 Hz και τα 4 Hz και εμφανίζεται, όταν τα μάτια είναι κλειστά σε έναν φυσιολογικό ενήλικα άνθρωπο.



Εικόνα 11: Ρυθμός Δέλτα - Άδεια δημοσίευσης GNU/GPL - Brainwave images © Hugo Gamboa Dez 2005 ([https://commons.wikimedia.org/wiki/File:Eeg\\_delta.svg](https://commons.wikimedia.org/wiki/File:Eeg_delta.svg))

Πρόσφατες μελέτες εισήγαγαν [134] τον εγκεφαλικό ρυθμό γάμα με συχνότητες που κυμαίνονται από 30 έως και 100 Hz. Την τελευταία δεκαετία έχει προσελκύσει το ενδιαφέρον των ερευνητών. Φαίνεται να σχετίζεται με την αντίληψη και τη συνείδηση καθώς και την ταυτόχρονη επεξεργασία πληροφοριών που πραγματοποιεί ο εγκέφαλος. Η εμφάνισή του στους ενήλικες, σε περιπτώσεις εκτός από τον ύπνο, μπορεί να είναι σημάδι εκδορών στον εγκεφαλικό φλοιό ή γενικότερα εγκεφαλοπαθειών.



Εικόνα 12: Ρυθμός Γάμα - Άδεια δημοσίευσης GNU/GPL - Brainwave images © Hugo Gamboa Dez 2005 ([https://commons.wikimedia.org/wiki/File:Eeg\\_gamma.svg](https://commons.wikimedia.org/wiki/File:Eeg_gamma.svg))

Συγκεντρωτικά οι ρυθμοί, οι συχνότητες και τα χαρακτηριστικά των ρυθμών εμφανίζονται στον Πίνακα 1

|          |                                                                                       |
|----------|---------------------------------------------------------------------------------------|
| Α ρυθμός | Συχνότητες 8 - 13 Hz. Εμφανίζεται όταν τα μάτια είναι κλειστά και το άτομο κοιμάται   |
| Β ρυθμός | Συχνότητες 13 - 30 Hz. Εμφανίζεται όταν τα μάτια είναι κλειστά και το άτομο κοιμάται  |
| Γ ρυθμός | Συχνότητες 35 - 100 Hz. Εμφανίζεται όταν τα μάτια είναι κλειστά και το άτομο κοιμάται |
| Δ ρυθμός | Συχνότητες 0.5 - 4 Hz. Εμφανίζεται όταν τα μάτια είναι κλειστά και το άτομο κοιμάται  |
| Θ ρυθμός | Συχνότητες 4 - 8 Hz. Εμφανίζεται όταν τα μάτια είναι κλειστά και το άτομο κοιμάται    |

Πίνακας 1 : Εγκεφαλικοί Ρυθμοί, συχνότητες και χαρακτηριστικά

Πιο περιγραφικά και, όπως προκύπτει από τις καταγραφές, [134], το σήμα του ΗΕΓ συσχετίζεται πολύ με το επίπεδο εγρήγορσης του εξεταζόμενου. Όταν η ανθρώπινη δραστηριοποίηση αυξάνεται, τότε το ΗΕΓ έχει υψηλότερη επικρατούσα συχνότητα και μικρότερο πλάτος. Όταν τα μάτια είναι κλειστά, ο ρυθμός άλφα είναι κυρίαρχος. Όταν ο εξεταζόμενος κοιμάται, η επικρατούσα συχνότητα του ΗΕΓ μειώνεται. Σε μια ορισμένη φάση ύπνου, που πραγματοποιείται γρήγορο ανοιγοκλείσιμο των ματιών και το άτομο ονειρεύεται, μπορεί να θεωρηθεί ως χαρακτηριστικό σήμα ΗΕΓ. Στον βαθύ ύπνο το ΗΕΓ έχει μεγάλες και αργές εκτροπές, που ονομάζονται ρυθμοί δέλτα. Τέλος,

καμία εγκεφαλική δραστηριότητα δεν μπορεί να ανιχνευθεί από έναν ασθενή σε πλήρη εγκεφαλικό θάνατο.

Βασικός ρυθμός ονομάζεται [134] η συνεχής HEΓ δραστηριότητα, η οποία κυριαρχεί σε ένα διάγραμμα. Στο φυσιολογικό άτομο συμπίπτει με το ρυθμό άλφα. Ειδικότερες κατηγοριοποιήσεις εγκεφαλικών ρυθμών, ανάλογα με το φάσμα συχνοτήτων και τη γενικότερη μορφολογία τους, έχουν επίσης αναφερθεί στη βιβλιογραφία, όπως οι ρυθμοί μι, κάππα και λάμδα.




### 3. ΜΕΘΟΔΟΙ ΕΠΕΞΕΡΓΑΣΙΑΣ ΚΑΙ ΚΑΤΗΓΟΡΙΟΠΟΙΗΣΗΣ ΣΗΜΑΤΩΝ

Στο παρόν κεφάλαιο παραθέτουμε έννοιες που βοηθούν στην κατανόηση επεξεργασίας των σημάτων και πιο συγκεκριμένα των Ηλεκτροεγκεφαλογραφικών σημάτων. Με τον όρο «σήμα» ο οποίος πιο συχνά χρησιμοποιείται στις τηλεπικοινωνίες, εννοούμε στην πραγματικότητα ένα σύνολο πληροφοριών, το οποίο πρέπει να μεταδοθεί από ένα σημείο (πηγή) σε ένα άλλο (δέκτης). Στην πραγματικότητα είναι μια συνάρτηση του χρόνου, που αντιπροσωπεύει κάποια φυσική ποσότητα, η οποία εμφανίζει ενδιαφέρον [105], [77], [86], [45].


Ως σήμα θεωρείται η τάση, τα κύματα από το radar, η ανθρώπινη ομιλία, μια εικόνα, το καρδιογράφημα και φυσικά το ηλεκτροεγκεφαλογράφημα.

Τα σήματα λαμβάνονται και καταγράφονται από κατάλληλες συσκευές (radar, sonars, ηλεκτροεγκεφαλογράφοι, καρδιογράφοι κ.τ.λ.). Η μέτρηση συνήθως συμβολίζεται με  $x(t)$ .

Ανάλογα με τον τύπο της ανεξάρτητης ή της εξαρτημένης μεταβλητής της συνάρτησης, τα σήματα διακρίνονται στις παρακάτω δύο βασικές κατηγορίες. Τα συνεχή-αναλογικά σήματα (Εικόνα 13) και τα διακριτά-ψηφιακά σήματα (Εικόνα 14).



**Εικόνα 13:** Συνεχές-Αναλογικό Σήμα



**Εικόνα 14:** Διακριτό-Ψηφιακό Σήμα

Σήματα συνεχούς χρόνου ή αναλογικά σήματα (Εικόνα 13) είναι τα σήματα των οποίων η ανεξάρτητη μεταβλητή μεταβάλλεται σ' ένα συνεχές διάστημα. Στα μονοδιάστατα σήματα το πεδίο ορισμού είναι η ευθεία των πραγματικών αριθμών. Επειδή η ανεξάρτητη μεταβλητή  $t$  συνήθως είναι ο χρόνος, τα σήματα αυτά ονομάζονται σήματα συνεχούς χρόνου ή σήματα συνεχούς μεταβλητής.

Σήματα διακριτού χρόνου (Εικόνα 14) είναι τα σήματα των οποίων το πεδίο ορισμού είναι κάποιο διακριτό σύνολο, (π.χ. το σύνολο των ακέραιων αριθμών), ενώ η εξαρτημένη μεταβλητή είναι δυνατόν να λαμβάνει οποιαδήποτε τιμή.

Στις επόμενες παραγράφους περιγράφονται διάφορες μέθοδοι επεξεργασίας αυτών των σημάτων.

### 3.1 Φασματική Ανάλυση

Η Φασματική Ανάλυση (ΦΑ) ενός σήματος είναι η μέτρηση της κατανομής της ισχύος του σήματος στο φάσμα των συχνοτήτων και ανήκει στις μεθόδους εξαγωγής χαρακτηριστικών μεγεθών σημάτων. Πιο συγκεκριμένα, η ΦΑ έχει ως στόχο να προσδιορίσει τη φασματική πυκνότητα ισχύος (power spectral density, PSD),  $P(\Omega)$ , του σήματος, ως συνάρτηση της συνεχούς κυκλικής συχνότητας  $\Omega$ . Επειδή τα σήματα διακριτού χρόνου, είναι καταλληλότερα για επεξεργασία μέσω ηλεκτρονικού υπολογιστή, συγκεντρώνουν και το περισσότερο ενδιαφέρον. Ένα μέρος της βιβλιογραφίας [104] [105,] [92], που αναφέρεται στη ΦΑ, θεωρεί το σήμα και ως στοχαστική διαδικασία διακριτού χρόνου. Σε αυτήν την περίπτωση, τόσο η πυκνότητα ισχύος  $P(\Omega)$  όσο και όλες οι



υπόλοιπες ποσότητες ορίζονται ως μέσες τιμές κάποιων πιθανοσυνόλων. Στην ανάλυση που θα ακολουθήσει θα διαπιστωθεί ότι αυτό δεν είναι πάντα απαραίτητο. Συνήθως στην πράξη διατίθεται πεπερασμένος αριθμός σημείων

$$\{X_n\}_{n=0}^{n-1}$$

μίας μόνο πραγματοποίησης της στοχαστικής διαδικασίας  $\{X_n\}$ . Από τα σημεία αυτά επιχειρείται να εκτιμηθεί η  $P(\Omega)$ . Διάφορες εκτιμήτριες συναρτήσεις έχουν προταθεί και καθεμία οδηγεί σε διαφορετικό αλγόριθμο ΦΑ. Η σύγκριση μεταξύ τους στηρίζεται στις αρχές της στατιστικής μεθοδολογίας [105].

Γενικά οι μέθοδοι ΦΑ διακρίνονται στις παρακάτω κατηγορίες:

- Μη παραμετρικές (θεωρούνται οι πιο κλασικές μέθοδοι), όπως για παράδειγμα ο Διακριτός Μετασχηματισμός Fourier, το Περιοδιόγραμμα, η μέθοδος Blackman-Tukey κ.α. [11], [48].
- Παραμετρικές, όπως για παράδειγμα, η γραμμική πρόβλεψη ή γραμμικό μοντέλο, η μέθοδος Burg, η μέθοδος Music, η μέθοδος ελαχίστου μέτρου, κ.α [18] [19].

Ειδικά οι παραμετρικές μέθοδοι στηρίζονται στη μοντελοποίηση του σήματος, σύμφωνα με κάποιο γραμμικό μοντέλο (ARMA, AR ή MA) [115] [71] ή στην ανάλυση ιδιοτιμών [22]. Με αυτόν τον τρόπο επιτυγχάνεται υψηλότερη διακριτική ικανότητα από τις μη παραμετρικές μεθόδους και παρέχεται η δυνατότητα μέτρησης της συχνότητας από πολύ μικρής διάρκειας σήμα καθώς και από πολύ χαμηλά επίπεδα SNR [23], [115], [22].


Στις επόμενες παραγράφους θα αναπτύξουμε περαιτέρω εκείνες τις μεθόδους τις οποίες χρησιμοποιήσαμε για την εξαγωγή των ιδιαίτερων χαρακτηριστικών από το προ-εξεργασμένο Ηλεκτροεγκεφαλογραφικό σήμα και πιο ιδιαίτερα στο κομμάτι στο οποίο εντοπίσθηκαν οι στάσιμες ιδιότητες.

### 3.1.1 Μη παραμετρικές μέθοδοι Φασματικής Ανάλυσης

Μια μη παραμετρική μέθοδος επεξεργασίας ενός διακριτού ηλεκτροεγκεφαλογραφικού σήματος είναι ο Διακριτός Μετασχηματισμός Fourier (Discrete Transform Fourier, DTF - Εικόνα 15) [82]. Η φασματική πυκνότητα ισχύος δίνεται από την εξίσωση 1.

$$R_f^x = \sum_{k=0}^{K-1} r_k^x e^{-j \frac{2\pi f k}{K}}, \quad f = 0, 1, \dots, K-1 \quad (1)$$


Τα χαρακτηριστικά (attributes) που πρόκειται να εξαχθούν με τη συγκεκριμένη μέθοδο είναι οι φασματικές συνιστώσες του προεξεργασμένου ΗΕΓ. Η υπολογιστική πολυπλοκότητα του προαναφερόμενου αλγόριθμου είναι  $O(n^2)$ .



**Εικόνα 15:** Σήματα Διακριτού Χρόνου με Ανάλυση Fourier DTF

Πρόκειται δηλαδή για τετραγωνική πολυπλοκότητα, όπου  $n$  είναι το μέγεθος των δεδομένων εισόδου του αλγόριθμου. Για να μειωθεί αυτή η πολυπλοκότητα, προτιμήθηκε να χρησιμοποιηθεί ο Ταχύς Μετασχηματισμός Fourier (Fast Fourier Transformation, FFT), βασιζόμενος στον αλγόριθμο του Tukey [11].

Ο συγκεκριμένος αλγόριθμος είναι η ταχύτερη μορφή του DFT αλγορίθμου [82] [125]. Ταχύς μετασχηματισμός Fourier (FFT) είναι το σύνολο των αλγορίθμων για την υλοποίηση του Διακριτού Μετασχηματισμού Fourier με περισσότερο αποδοτικό τρόπο.



**Εικόνα 16:** Ανάλυση Fast Fourier FFT  
(public domain image, free to use, share or modify, even commercially)

Ο FFT χρησιμοποιεί την τεχνική "διαίρει - και βασίλευε" της Θεωρίας Αλγορίθμων, και μειώνει την πολυπλοκότητα από  $O(n^2)$  που δίνει ο DFT σε  $O(n \cdot \log 2n)$ . Τελικά, οι φασματικές συνιστώσες που λαμβάνονται από τον μετασχηματισμό FFT χρησιμοποιούνται στη συνέχεια ως ιδιαίτερα χαρακτηριστικά του προεπεξεργασμένου σήματος.

### 3.1.2 Παραμετρικές μέθοδοι Φασματικής Ανάλυσης

Η πιο σημαντική από τις μεθόδους παραμετρικής Φασματικής Ανάλυσης είναι το γραμμικό μοντέλο [157], [19], [20], [34], [35], [40], [61]. Μία αρκετά γενική και πολύ διαδεδομένη κατηγορία γραμμικών μοντέλων είναι τα μοντέλα τύπου Autoregressive - Moving Average (ARMA) τάξεως  $(p,r)$  [115], [71]. Επίσης η επέκταση του γραμμικού αυτού μοντέλου είναι δυνατό να περιλάβει μη γραμμικά δυναμικά (non-linear dynamics) μοντέλα. Αυτό οδηγεί σε μια δεύτερη μέθοδο ανάλυσης. Στις επόμενες παραγράφους θα αναπτυχθούν οι συγκεκριμένες μορφές των προαναφερόμενων παραμετρικών φασματικών μεθόδων, που χρησιμοποιήθηκαν στην παρούσα διατριβή για την εξαγωγή των ιδιαίτερων χαρακτηριστικών του ΗΕΓ. Τα ιδιαίτερα αυτά χαρακτηριστικά

αφορούν τη φασματική ανάλυση και τον δείκτη της φασματικής ισχύος που αναλυτικά αναφέρεται στο 4.3.6 και τον οποίο χρησιμοποιήσαμε, προκειμένου να επιτύχουμε πρόβλεψη συμπεριφοράς. Τα αποτελέσματα αναφέρονται στην παράγραφο 6.3.3.

## Γραμμικές Παραμετρικές μέθοδοι Φασματικής Ανάλυσης

Για την εξαγωγή του δείκτη της φασματικής ισχύος χρησιμοποιήθηκε το γραμμικό μοντέλο ARMA (p,r), όπως το περιγράψαμε στο τέλος της προηγούμενης παραγράφου [115], [71]. Το γραμμικό αυτό μοντέλο είναι προσαρμοσμένο στο προ-εξεργασμένο ΗΕΓ  $\{y_n\}$ . Το στοχαστικό αυτό σήμα διακριτού χρόνου  $\{y_n\}$  περιγράφεται επιτυχημένα από ένα τέτοιο μοντέλο, αν υπακούει στην παρακάτω σχέση [157] [19], [20], [34], [35], [40], [61]:

$$y_n + \sum_{i=1}^p a_i y_{n-i} = \sum_{j=0}^r c_j e_{n-j} \quad (2)$$

όπου:

- η  $\{e_n\}$  είναι διαδικασία λευκού θορύβου, μηδενικής μέσης τιμής και αγνώστου διακύμανσης  $\sigma_e^2$
- $c_0 = 1$
- οι παράμετροι  $\{a_i, i=1, \dots, p\}, \{c_j, j=1, \dots, r\}$  είναι άγνωστες σταθερές.

Μεταφέροντας την εξίσωση (2) στο μιγαδικό επίπεδο z, βλέπουμε ότι μία διαδικασία ARMA(p,r) μπορεί να προκύψει ως έξοδος ενός γραμμικού, χρονικά αμετάβλητου συστήματος (φίλτρου), το οποίο διεγείρεται από λευκό θόρυβο [115], [71]. Το φίλτρο έχει την παρακάτω ρητή συνάρτηση μεταφοράς :

$$H(z) = \frac{C(z)}{Z(z)} = \frac{c_o + \sum_{j=0}^r c_j z^{n-j}}{1 + \sum_{j=1}^p a_j z^{n-j}} \quad (3)$$

Στην προτεινόμενη μέθοδο για λόγους μείωσης της πολυπλοκότητας της μεθόδου, οι ΜΑ συντελεστές  $\{c_j, j = 1, \dots, r\}$  απαλείφθηκαν και έτσι υιοθετήθηκε ένα καθαρά AR μοντέλο. Έτσι η εξίσωση (2) τροποποιείται ως ακολούθως:

$$y_n + \sum_{i=1}^p a_i y_{n-i} = c_0 e_n \quad (4)$$

Η επιλογή της τάξης (p) του επιλεγμένου μοντέλου AR γίνεται σύμφωνα με το κριτήριο AIC (Akaike Information Criterion), το οποίο δίνεται από την παρακάτω εξίσωση:

$$AIC(r) = (N - M) \log \sigma_e^2 + 2r \quad (5)$$

$$\sigma_e^2 = \frac{1}{N - M} \sum_{t=M+1}^N e_t^2 \quad (6)$$

όπου:

N είναι αριθμός των διακριτών τιμών του σήματος,

M είναι η μέγιστη τάξη που δύναται να περιγράψει το μοντέλο,

r είναι ο αριθμός ανεξαρτήτων μεταβλητών που περιγράφουν το μοντέλο.

Ο βέλτιστος βαθμός r προκύπτει από την ελαχιστοποίηση του AIC(r). Για τον υπολογισμό των συγκεκριμένων p παραμέτρων,  $\{a_i, i = 1, \dots, p\}$  από το προεπεξεργασμένο σήμα ΗΕΓ χρησιμοποιείται ένα γραμμικό μοντέλο

αυτοσυσχέτισης δεύτερης τάξης [118]. Εδώ φαίνεται και η μείωση της πολυπλοκότητας από τη χρήση αμιγώς AR μοντέλου, διότι στην περίπτωση που υπήρχαν και οι MA συντελεστές, η τάξη της αυτοσυσχέτισης θα έπρεπε να είναι τουλάχιστον τρίτη. Από την άλλη πλευρά έχειδειχθεί ότι το ΗΕΓ δύναται να περιγραφεί ικανοποιητικά από αυτοσυσχέτιση δεύτερης τάξης. Συνεπώς, το παρακάτω πλήρες ορισμένο σύστημα εξισώσεων βασίζεται σε αποκλειστικά AR παραμέτρους [34], [35], [40]

$$r_k^y + \sum_{i=1}^p a_i r_{k-1}^y = 0, \quad k \geq 0 \quad (7)$$

όπου  $\{r_k^y, \quad k = 0, 1, 2, \dots, y\}$ , οι συντελεστές αυτοσυσχέτισης του σήματος. Ένα σύστημα ανεξαρτήτων εξισώσεων μπορεί να δημιουργηθεί από την εξίσωση (7) για διαφορετικές τιμές του  $k$ . Σε μορφή πίνακα, το γραμμικό αυτό σύστημα μπορεί να περιγραφεί ως:

$$C_a = 0 \quad (8)$$

όπου  $C$  είναι ο πίνακας διαστάσεων  $(k \times y)$  που περιέχει τους συντελεστές αυτοσυσχέτισης, ενώ το διάνυσμα

$$a = [1, a_1, \dots, a_p] \quad (9)$$

περιέχει τις άγνωστες παραμέτρους AR. Σημειώνεται ότι συνεπείς εκτιμήτριες των παραμέτρων AR μπορούν να ληφθούν από την επίλυση του συστήματος που περιγράφεται από την εξίσωση 7, μόνο εάν ισχύει για τον βαθμό του πίνακα  $C$  η σχέση :

$$\text{rank}[C] = p \quad (10)$$

## Μη Παραμετρικές γραμμικές μέθοδοι Φασματικής Ανάλυσης

Για μια πιο ολοκληρωμένη θεώρηση του μοντέλου που περιγράψαμε στην προηγούμενη παράγραφο, συζητάμε σε αυτήν την παράγραφο μία επέκταση του προηγούμενου μοντέλου τύπου AR με μη γραμμικούς και συγκεκριμένα διγραμμικούς (bilinear) συντελεστές τάξεων  $(p, 0, m, k)$  [116], [15], [20], [30], [32]. Οι εξαγόμενοι διγραμμικοί συντελεστές εξαρτώνται άμεσα από τους γραμμικούς συντελεστές  $AR(p)$ . Η προτεινόμενη μη γραμμική επέκταση της μεθόδου έχει σκοπό να εξαχθούν επιπλέον μη γραμμικά χαρακτηριστικά που περιέχουν ακριβέστερη πληροφορία απ' ό,τι το καθαρά γραμμικό AR μοντέλο, σχετικά με το προ-επεξεργασμένο ΗΕΓ. Το μοντέλο αυτό δύναται να θεωρηθεί ως μια επεκταμένη μορφή της εξίσωσης (4). Η παράλειψη του MA τμήματος της εξίσωσης (2) του μοντέλου είναι μία συμβιβαστική λύση, για να διευκολυνθεί η εκτίμηση των προαναφερόμενων παραμέτρων με γραμμικό τρόπο. Αυτή η απλοποιημένη επιλογή περιγράφεται από την παρακάτω εξίσωση:

$$x_t + \sum_{i=1}^p a_i x_{t-i} = a + \sum_{i=1}^k \sum_{j=1}^m b_{ij} x_{t-i} e_{t-j} + e_t \quad (11)$$

Η μονοδιάστατη παράμετρος  $a$  έχει εισαχθεί στην εξίσωση (11), ώστε να επιτραπεί η προσαρμογή του μοντέλου σε δεδομένα με μη μηδενικές μέσες τιμές. Στη παρούσα περίπτωση απαλείφεται η παράμετρος  $a$ , γιατί έχουν μηδενιστεί οι μέσες τιμές του τμήματος του ΗΕΓ πριν από κάθε περαιτέρω επεξεργασία.

Η εκλογή της τάξης του γραμμικού μοντέλου είναι συνήθως βασισμένη σε ένα από τα κριτήρια της Θεωρίας Πληροφορίας, όπως το AIC που περιγράφεται από την εξίσωση (5). Το κριτήριο AIC χρησιμοποιήθηκε, ώστε να εκτιμηθεί η τάξη του γραμμικού τμήματος του μοντέλου της εξίσωσης (11), που στην προκειμένη περίπτωση είναι η καταλληλότερη τάξη  $p$  του AR τμήματος του μοντέλου. Για κάθε υποψήφια τάξη  $p$  σε ένα εύρος τιμών  $[p_{\min}, p_{\max}]$ , ο  $AIC(p)$  υπολογίζεται από τα υπόλοιπα (residuals) κάθε εγγραφής εντός του συνολικού

καταγεγραμμένου αριθμού σημάτων ΗΕΓ. Η διαδικασία της εκτίμησης των παραμέτρων ενός προσαρμοσμένου μοντέλου που περιγράφεται από την εξίσωση (11) απαραίτητα προϋποθέτει την εφαρμογή της Μεθόδου των Επαναλαμβανόμενων Υπολοίπων (Repeated Residuals) [116], [15]. Τα βασικά βήματα της παραπάνω μεθόδου περιγράφονται εδώ χάριν της πληρότητας της παρουσίασης. Παρακάτω υποθέτουμε ότι :

- Οι τάξεις  $(p, m, k)$  του μοντέλου της εξίσωσης (11) είναι γνωστές και σταθερές.
- Η  $\{e_t\}$  είναι μία στοχαστική διαδικασία ανεξάρτητων δειγμάτων ομοιόμορφης κατανομής και μηδενικής μέσης τιμής.
- $\{x_1, x_2, \dots, x_n\}$  περιγράφει μία πραγματοποίηση της χρονοσειράς  $\{x_t\}$  μήκους  $n$  δειγμάτων (στην παρούσα εργασία η χρονοσειρά  $\{x_t\}$  είναι οι τιμές του κάθε καταγεγραμμένου σήματος ΗΕΓ).

### 3.2 Ανάλυση FOURIER

Η ανάλυση Fourier είναι ένα πεδίο των εφαρμοσμένων μαθηματικών, το οποίο προέκυψε από την προσπάθεια αναπαράστασης μίας συνάρτησης ως άθροισμα απλούστερων περιοδικών τριγωνομετρικών συναρτήσεων. Επομένως κεντρική ιδέα στην ανάλυση Fourier είναι η προσπάθεια για κατανόηση των ιδιοτήτων μίας συνάρτησης (η οποία μπορεί να αναπαριστά π.χ. ένα σήμα) μέσω διάσπασής της σε γνωστά, στοιχειώδη μέρη, όπως είναι η αποσύνθεση. Η ανάστροφη διαδικασία, η κατασκευή μίας συνάρτησης από γνωστές βασικές συναρτήσεις ονομάζεται σύνθεση. Με τον όρο ανάλυση Fourier αναφερόμαστε και στις δύο διεργασίες. Η μέθοδος αυτή εφαρμόστηκε για πρώτη φορά από τον Jean-Baptiste Joseph Fourier (21 March 1768 – 16 May 1830), στην προσπάθειά του να ερευνήσει τη διάδοση της θερμότητας.



### **3.2.1 Μετασχηματισμός FOURIER**

Ο όρος μετασχηματισμός Fourier αναφέρεται σε μία αυστηρώς ορισμένη μαθηματική διεργασία, η οποία αποσυνθέτει μία συνάρτηση σε άθροισμα απείρων περιοδικών ημιτονοειδών και συνημιτονοειδών συναρτήσεων. Το αποτέλεσμα του μετασχηματισμού είναι μία νέα συνάρτηση με διαφορετικό πεδίο ορισμού, η οποία περιγράφει το κατά πόσο συμμετέχει κάθε στοιχειώδες ημίτονο στον σχηματισμό της αρχικής συνάρτησης.

Η σειρά Fourier εφαρμόζεται για περιοδική  $f$  και δίνει ως αποτέλεσμα μία νέα συνάρτηση με διακριτό πεδίο τιμών αντί για συνεχές. Αυτό σημαίνει ότι πεδίο τιμών σε μια σειρά Fourier είναι οι φυσικοί αριθμοί και όχι οι πραγματικοί.

Για συναρτήσεις διακριτής ανεξάρτητης μεταβλητής, όπου οι φυσικοί αριθμοί είναι το πεδίο ορισμού της  $f$  υπάρχουν :

- Ο μετασχηματισμός Fourier διακριτού χρόνου με συνεχές πεδίο τιμών που είναι κατάλληλος για μη περιοδικές συναρτήσεις.
- Ο διακριτός μετασχηματισμός Fourier (*Εικόνα 15*) με διακριτό πεδίο τιμών που είναι κατάλληλος για περιοδικές συναρτήσεις.

Για κάθε μία περίπτωση υπάρχει και ο αντίστροφος μετασχηματισμός, ο οποίος δέχεται ως είσοδο το φάσμα και δίνει ως έξοδο την αρχική συνάρτηση  $f$ .

### **3.2.2 Εφαρμογές Μετασχηματισμού Fourier**

Ο μετασχηματισμός Fourier μπορεί να χρησιμοποιηθεί στη Φυσική, στη Στατιστική, στην Κρυπτογραφία, στην επεξεργασία εικόνας, στην επεξεργασία σήματος κ.ά., διότι προσφέρει χρήσιμες ιδιότητες των ολοκληρωτικών μετασχηματισμών:

Οι μετασχηματισμοί είναι γραμμικοί τελεστές και επίσης είναι μοναδιαίοι.

- Οι μετασχηματισμοί είναι συνήθως αντιστρέψιμοι.

- Από το θεώρημα της συνέλιξης, οι μετασχηματισμοί Fourier μετατρέπουν τη συνέλιξη σε απλό πολλαπλασιασμό, το οποίο σημαίνει ότι παρέχουν ένα αποτελεσματικό τρόπο, για να υπολογιστούν διαδικασίες που βασίζονται στη συνέλιξη, όπως πολλαπλασιασμός πολυωνύμων και πολλαπλασιασμός μεγάλων αριθμών.
- Οι εκθετικές συναρτήσεις είναι ιδιοσυναρτήσεις της παραγωγής, το οποίο σημαίνει ότι αυτή η αναπαράσταση μετασχηματίζει γραμμικές διαφορετικές εξισώσεις με σταθερούς συντελεστές σε κανονικές αλγεβρικές.

Στο ΠΑΡΑΡΤΗΜΑ Γ μπορεί κανείς να βρει όλες τις βασικές σχέσεις που διέπουν το μετασχηματισμό Fourier.

Στην εργασία μας χρησιμοποιήσαμε την ανάλυση Fourier και πιο συγκεκριμένα τον γρήγορο μετασχηματισμό (Fast Fourier Transformation – FFT - *Εικόνα 16*) στη μέθοδο εντοπισμού στάσιμων σημείων σε ένα ηλεκτροεγκεφαλογραφικό σήμα.

### **3.3 Κατηγοριοποίηση - Ταξινόμηση Σημάτων**

#### **3.3.1 Γραμμικές και μη γραμμικές μέθοδοι**

Η κατηγοριοποίηση ή αλλιώς ταξινόμηση όπως ονομάζεται (classification) είναι μια διαδικασία, η οποία ομαδοποιεί δεδομένα και χρησιμοποιείται ως μέθοδος εξόρυξης γνώσης. Αυτό συμβαίνει με την κατηγοριοποίηση ξεχωριστών δεδομένων. Στη συγκεκριμένη διδακτορική διατριβή, η κατηγοριοποίηση χρησιμοποιείται, με σκοπό να εξαχθούν κατάλληλα χαρακτηριστικά τα οποία θα βοηθήσουν στην πρόβλεψη της δυσκολίας την οποία αντιμετωπίζει ένα άτομο, όταν εκτελεί μια εκπαιδευτική διαδικασία. Η διαδικασία της κατηγοριοποίησης μαζί με την ανάλυση των δεικτών που χρησιμοποιήθηκαν περιγράφεται στο 4.3, ενώ τα αποτελέσματα περιγράφονται στο 6.3.

Η διαδικασία λοιπόν της κατηγοριοποίησης σχετίζεται με την εξαγωγή κάποιων χαρακτηριστικών του σήματος. Το επόμενο βήμα, μετά την εξαγωγή των χαρακτηριστικών από το σήμα ΗΕΓ, είναι η κατηγοριοποίηση των αντίστοιχων διανυσμάτων ανά κατηγορία που αντιστοιχεί σε συγκεκριμένο άτομο [81]. Στην οικογένεια των κατηγοριοποιητών διακρίνουμε διάφορες υποδιαιρέσεις με αντίστοιχα κριτήρια (γραμμικοί / μη - γραμμικοί, προσαρμοστικοί / μη - προσαρμοστικοί, με επίβλεψη / χωρίς επίβλεψη κ.τ.λ.). Στην εργασία μας χρησιμοποιούμε κατάλληλα λογισμικά, τα οποία διαθέτουν αλγόριθμους οι οποίοι εκτελούν κατηγοριοποιήσεις και δίνουν ποσοστά ορθής κατηγοριοποίησης. Στη συνέχεια εξετάζονται εν συντομία οι κυριότερες μέθοδοι τις οποίες μπορούμε να ακολουθήσουμε, προκειμένου να επιτύχουμε την καλύτερη κατηγοριοποίηση, με σκοπό τελικά να επιλέξουμε την καταλληλότερη για το πρόβλημά μας.

### **Γραμμική μέθοδος.**

Τα προαναφερόμενα διανύσματα χαρακτηριστικών, τα οποία χρησιμοποιούνται ως διανύσματα εισόδου στον κατηγοριοποιητή, συσχετίζονται με τα διανύσματα εξόδου, τα οποία προκύπτουν μετά τη διαδικασία εκμάθησης των εισαγόμενων διανυσμάτων από ένα επιλεγμένο σύστημα κατηγοριοποίησης, με γραμμικό τρόπο. Ειδικότερα, αν θεωρηθούν  $x_i$  τα διανύσματα εισόδου και  $y_j$  τα διανύσματα εξόδου και  $\mu_{ij}$  είναι τα διανύσματα διαχωρισμού ανά κατηγορία των διανυσμάτων εισόδου (βάρη), τότε η γραμμική συσχέτιση των διανυσμάτων  $x_i$ ,  $y_j$  δίνεται από την παρακάτω σχέση:


$$y_i = \sum_{j=1}^k \mu_{ij} x_i \quad (12)$$

Για καλύτερη κατανόηση της μεθόδου μπορεί να χρησιμοποιηθεί ένα πολύ απλό σύστημα κατηγοριοποιητή, που η βασική του ιδέα είναι η θεώρηση του αμφιβληστροειδή ως δισδιάστατης διάταξης φωτοαισθητήρων [141].

Τα φωτοαισθητήρια συνδέονται πλήρως ή τυχαία με αμετάβλητα βάρη  $w_{ij}$  με ανιχνευτές χαρακτηριστικών (Τεχνητοί Νευρώνες, (TN)) που έχουν την ικανότητα να αναγνωρίζουν κάποια συγκεκριμένα πρότυπα. Για να δραστηριοποιηθεί κάποιος TN, πρέπει το σταθμισμένο άθροισμα εισόδου να είναι ως εξής (μετασχηματισμός της εξίσωσης (12) ) (Εικόνα 17)

$$NET_j = \sum_{i=1}^k w_{ij} x_i \geq 0 \quad (13)$$

όπου  $i, j$ : είναι ο αριθμός των εισόδων και των εξόδων αντίστοιχα. Ακόμη υπάρχει το επίπεδο εξόδου που αποτελείται από TN που λειτουργούν ως «ανιχνευτές προτύπων» και συνδέονται με μεταβλητά βάρη και τυχαίο τρόπο με κάποιους από τους ανιχνευτές χαρακτηριστικών.



**Εικόνα 17:** Γραμμική συνάρτηση κατωφλίου που χρησιμοποιείται ως συνάρτηση μεταφοράς για τους ανιχνευτές χαρακτηριστικών και τους ανιχνευτές προτύπων. Η αύξηση της δραστηριοποίησης από κάποιο σημείο και μετά είναι γραμμική (Α). Μία εναλλακτική συνάρτηση μεταφοράς για τους ανιχνευτές προτύπων (Β).

Ως συνάρτηση μεταφοράς χρησιμοποιείται η γραμμική συνάρτηση κατωφλίου (Εικόνα 17α). Αυτά τα χαρακτηριστικά του κατηγοριοποιητή προέρχονται από φυσιολογικές παρατηρήσεις. Έτσι π.χ. στην περίπτωση του αμφιβληστροειδή οι νευρώνες πυροδοτούνται, μόνον όταν η δραστηριότητα εισόδου υπερβεί κάποιο κατώφλι.

Στη συνέχεια ο ρυθμός πυροδότησης αυξάνει ανάλογα με την αύξηση της εισόδου. Εναλλακτικά μπορούμε να χρησιμοποιήσουμε μια βηματική συνάρτηση μεταφοράς, η οποία κβαντίζει την έξοδο του TN στην τιμή 0, αν το σταθμισμένο άθροισμα εισόδου  $NET_j \leq 0$  ή στην τιμή 1, αν το σταθμισμένο άθροισμα εισόδου  $NET_j \geq 0$  (Εικόνα 17b).

### **Μη γραμμική μέθοδος.**


Τα διανύσματα εξόδου τα οποία προέκυψαν από μία γραμμική διεργασία, μεταφέρουν συνήθως κάποιες ανεπιθύμητες συνιστώσες [141]. Η απόρριψη των συνιστωσών αυτών γίνεται με την ενσωμάτωση στη γραμμική εξίσωση ενός μη γραμμικού τμήματος  $\gamma_i(y_j)$  που είναι παρόμοιο με ένα βαθμωτό πεδίο. Κατόπιν τούτου η εξίσωση τροποποιείται δια της μη γραμμικής ολοκλήρωσής της, ως ακολούθως :

$$\frac{dy_i}{dt} = y_i - \gamma_i(y_j) \quad (14)$$

Για καλύτερη κατανόηση της μη γραμμικής μεθόδου αναφέρεται η περίπτωση του σιγμοειδούς μοντέλου (εικόνα 11). Το σιγμοειδές μοντέλο είναι αυτό που χρησιμοποιείται περισσότερο στην πράξη. Ονομάστηκε έτσι από τη μορφή της μη γραμμικότητάς του. Μία δημοφιλής επιλογή είναι η λογιστική συνάρτηση:

$$f(u) = \frac{1}{1 + e^{-au}} \quad (15)$$

Καθώς το  $a \rightarrow +\infty$  από το σιγμοειδές μοντέλο μετατρέπεται σε γραμμικό μοντέλο.



**Εικόνα 18:** Μη γραμμική συνάρτηση κατωφλίου που χρησιμοποιείται ως συνάρτηση μεταφοράς για τους ανιχνευτές χαρακτηριστικών και τους ανιχνευτές προτύπων (σιγμοειδής συνάρτηση).

### 3.3.2 Μέθοδοι με επίβλεψη και χωρίς επίβλεψη

Αν θεωρηθεί ότι τα διανύσματα εισόδου (εδώ διανύσματα επεξεργασίας ΗΕΓ) αποτελούνται από  $d$  μεταβλητές, δηλαδή ο υπερχώρος των διανυσμάτων εισόδου έχει διάσταση  $d$  και κάθε μεταβλητή λαμβάνει  $N$  διακριτές τιμές, τότε ο υποχώρος των διανυσμάτων αποτελείται από  $N^d$  διανύσματα εισόδου που λαμβάνουν  $N$  διακριτές τιμές. Μπορούμε να φανταστούμε ότι με την εκπαίδευση το σύστημα κατηγοριοποίησης σχηματίζει υποθέσεις για το ποιόν της υποκείμενης συνάρτησης εισόδου / εξόδου. Τα εκπαιδευτικά διανύσματα εισόδου είναι τα «στοιχεία» που βοηθούν στην ανακάλυψη της σωστής συνάρτησης. Βέβαια, όσο πιο μεγάλο είναι το μέγεθος του συστήματος

κατηγοριοποίησης τόσο περισσότερες συναρτήσεις μπορεί να υλοποιήσει και επομένως αυξάνει η πιθανότητα η επιθυμητή συνάρτηση να βρίσκεται σε αυτό το σύνολο συναρτήσεων.

Αν λάβουμε υπόψη ότι το μέγεθος του συστήματος κατηγοριοποίησης των ΗΕΓραφικών χαρακτηριστικών διανυσμάτων είναι αρκετά μεγάλο, ώστε να συμπεριλαμβάνει την επιθυμητή συνάρτηση, τότε μπορούμε να θεωρήσουμε ότι τα εκπαιδευτικά διανύσματα εισόδου μας δίνουν τη δυνατότητα απόρριψης των ανεπιθύμητων συναρτήσεων. Όσο περισσότερα εκπαιδευτικά διανύσματα διαθέτουμε τόσο περισσότερες συναρτήσεις μπορούμε να απορρίψουμε. Αν όμως το μέγεθος του συστήματος κατηγοριοποίησης δεν είναι αρκετά μεγάλο, τότε το σύστημα κατηγοριοποίησης αναζητεί τη συνάρτηση που ταιριάζει καλύτερα στην επιθυμητή.

Υπάρχει μια πληθώρα αλγορίθμων οι οποίοι χρησιμοποιούνται για την «εκπαίδευση» των συστημάτων κατηγοριοποίησης. Στην πράξη η εκπαίδευση κάποιου συστήματος κατηγοριοποίησης ισοδυναμεί με την ενδυνάμωση ή αποδυνάμωση των τιμών των βαρών (διανύσματα διαχωρισμού των διανυσμάτων εισόδου ανά κατηγορία προέλευσης), σύμφωνα με τους κανόνες που ορίζει ο αλγόριθμος εκπαίδευσης, μέχρι που τα βάρη να συγκλίνουν στις καταλληλότερες τιμές. Οι μεθοδολογίες εκπαίδευσης που χρησιμοποιούνται είναι :

- Με εποπτεία από εξωτερική πηγή ή με επίβλεψη (supervised).
- Χωρίς εποπτεία ή χωρίς επίβλεψη (unsupervised).

Κατά την εκπαίδευση με επίβλεψη παρουσιάζονται στο σύστημα κατηγοριοποίησης ζευγάρια διανυσμάτων εισόδου - εξόδου και το σύστημα αυτό προσπαθεί να κατασκευάσει μία σχέση (συνάρτηση) μεταξύ των διανυσμάτων αυτών όσο το δυνατόν πιστότερη. Πιο συγκεκριμένα, κάποιος αλγόριθμος καθοδήγησης από εξωτερική πηγή ακολουθεί μια επαναληπτική διαδικασία βήμα προς βήμα σύμφωνα με την οποία τροποποιούνται οι τιμές των βαρών. Η επαναληπτική διαδικασία σταματάει, όταν ελαχιστοποιηθεί κάποια

συνάρτηση σφάλματος, η οποία δίνει το μέτρο της διαφοράς της πραγματικής εξόδου από την επιθυμητή έξοδο του συστήματος. Το βασικό μειονέκτημα της μεθόδου είναι η πιθανότητα παγίδευσης του συστήματος σε κάποιο τοπικό ελάχιστο. Κλασικό παράδειγμα συστήματος εκπαίδευσης με επίβλεψη εκτελεί το νευρωνικό δίκτυο Learning Vector Quantization (LVQ).

Κατά την εκπαίδευση χωρίς επίβλεψη παρουσιάζονται στο σύστημα κατηγοριοποίησης μόνο τα διανύσματα εισόδου τα οποία ταξινομούνται σε κατηγορίες ανάλογα με τη σχετική ομοιότητα τους (αυτο-οργάνωση του συστήματος κατηγοριοποίησης). Πιο συγκεκριμένα κάποιος αλγόριθμος χωρίς επίβλεψη πραγματοποιεί ψευδοτυχαίες μεταβολές των τιμών των βαρών. Από τις μεταβολές διατηρούνται μόνο αυτές που βελτιώνουν (ελαχιστοποιούν) τη συνάρτηση σφάλματος. Το σημαντικότερο μειονέκτημα αυτής της μεθόδου είναι ο μεγάλος χρόνος που απαιτείται για την εύρεση του ολικού ελαχίστου.

Συμπερασματικά, μία από τις σημαντικές διαφορές των δύο μεθόδων είναι ότι ενώ η μέθοδος με επίβλεψη χρειάζεται εκ των προτέρων την πληροφορία της οργάνωσης των διανυσμάτων σε ομάδες ομοιότητας, η μέθοδος χωρίς επίβλεψη χρησιμοποιεί, κατά το στάδιο εκπαίδευσης των διανυσμάτων εισόδου, κατηγορίες χωρίς να είναι γνωστή η πληροφορία προέλευσής τους. Χαρακτηριστικά παραδείγματα της κατηγορίας εκπαίδευσης χωρίς επίβλεψη είναι η μέθοδος εκπαίδευσης του νευρωνικού δικτύου Self Organising Map (SOM), όπως επίσης και η ανάλυση τύπου clustering.

### **3.3.3 Τεχνητά Νευρωνικά Δίκτυα**

Το Τεχνητό Νευρωνικό Δίκτυο (ΤΝΔ) είναι ένα υπολογιστικό σύστημα που εκτελεί ορισμένες τουλάχιστον από τις χαρακτηριστικές λειτουργίες των Πραγματικών Νευρωνικών Δικτύων (ΠΝΔ). Μερικά από τα πλεονεκτήματα των ΤΝΔ είναι:

- Παράλληλη επεξεργασία



- Μνήμη.
- Ικανότητα εκμάθησης τυχαίων συναρτήσεων εισόδου/ εξόδου.
- Ικανότητα προσαρμογής.
- Απλές υπολογιστικές μονάδες (τεχνητοί νευρώνες, TN).

Δύο (2) από τα πιο δημοφιλή νευρωνικά δίκτυα είναι τα LVQ και RBF.

### **Learning Vector Quantizer (LVQ)**

Το νευρωνικό δίκτυο τύπου LVQ προτάθηκε από τον Kohonen το 1990 [54]. Τυπικά το LVQ αποτελείται από το επίπεδο εισόδου, από το κρυφό επίπεδο που χωρίζεται σε ομάδες TN, ανάλογα με τον αριθμό των κατηγοριών ταξινόμησης, και από το επίπεδο εξόδου που διαθέτει τόσους TN όσες και οι κατηγορίες ταξινόμησης. Το επίπεδο εισόδου συνδέεται πλήρως και με μεταβλητά βάρη με το κρυφό επίπεδο. Οι TN κάποιας ομάδας του κρυφού επιπέδου συνδέονται μόνο με έναν TN του επιπέδου εξόδου, δηλαδή με τον TN που αντιπροσωπεύει την κατηγορία τους και μάλιστα με σταθερά αμετάβλητα βάρη. Πριν από την εκπαίδευση όλα τα μεταβλητά βάρη έχουν μικρές τυχαίες τιμές. Ο αλγόριθμος εκπαίδευσης του LVQ διαθέτει:

- Στοιχεία εκπαίδευσης με επίβλεψη, επειδή επιλέγουμε αυθαίρετα κάποιον TN του επιπέδου εξόδου, για να εκπροσωπήσει μια κατηγορία.
- Ανταγωνιστικό τρόπο εκπαίδευσης, επειδή οι TN του κρυφού επιπέδου που ανήκουν στην ίδια κατηγορία ανταγωνίζονται μεταξύ τους για το ποιος θα αντιπροσωπεύσει το διάνυσμα εισόδου.

### **Νευρωνικό δίκτυο Τύπου Radial Basis Function (RBF)**

Ένα άλλο δημοφιλές νευρωνικό δίκτυο είναι το νευρωνικό δίκτυο RBF [16]. Η αρχιτεκτονική του νευρωνικού δικτύου RBF στηρίζεται σε τοπολογική διασταύρωση δύο μεθόδων εκπαίδευσης με και χωρίς επίβλεψη, (μη) εποπτείας. Η κατασκευή του αλγορίθμου στηρίζεται στη βασική μορφή τριών επιπέδων. Το

επίπεδο εισόδου είναι κατασκευασμένο από νευρώνες εισόδου (αισθητήρες). Το δεύτερο επίπεδο είναι κρυφό και δύναται να δεχθεί αρκετά υψηλής διαστάσεως διανύσματα, κατάλληλα τροποποιημένα από το προηγούμενο επίπεδο. Τέλος το τρίτο επίπεδο αποτελεί το επίπεδο εξόδου και είναι κατασκευασμένο, για να ανταποκρίνεται κατάλληλα στη δραστηριοποίηση του επιπέδου εισόδου. Ο μετασχηματισμός από το πρώτο επίπεδο εισόδου στο δεύτερο (κρυφό) επίπεδο είναι μη γραμμικός, ενώ ο μετασχηματισμός από το δεύτερο (κρυφό) επίπεδο στο επίπεδο εξόδου γίνεται με γραμμικό τρόπο. Η μαθηματική δικαιολογία της φύσης των προαναφερόμενων μετασχηματισμών ανά επίπεδο παρέχεται από το θεώρημα του Cover [27].

### **3.3.4 Εμπειρικές μέθοδοι Κατηγοριοποίησης / Ταυτοποίησης**

Πέρα από τις προαναφερόμενες μεθόδους κατηγοριοποίησης έχουν κατά καιρούς προταθεί πλήθος μεθόδων που αντιμετωπίζουν με αυξημένη επιτυχία συγκεκριμένα προβλήματα, χωρίς να στηρίζονται σε μία γενικευμένη μεθοδολογία. Οι μέθοδοι αυτές αναφέρονται ως εμπειρικές, σε αντιδιαστολή με τις προηγούμενες. Για το σκοπό της παρούσας εργασίας χρησιμοποιήθηκε μια τέτοια μέθοδος κατηγοριοποίησης βασισμένη σε Αλγορίθμους Υπολογιστικής Γεωμετρίας (Computational Geometry Algorithms, CGA). Ο σκοπός της ανάπτυξης της μεθόδου αυτής είναι να εκμεταλλευτεί τις ιδιαιτερότητες των ιδιοτήτων του ΗΕΓραφήματος, ώστε να γίνει με μεγαλύτερη επιτυχία η κατηγοριοποίησή του.

### **Η θεμελιώδης αρχή της Μεθόδου**

Η μέθοδος CGA δύναται να θεωρηθεί ως εμπειρική μέθοδος και στηρίζεται στην εμπειρική φιλοσοφική θεώρηση της απλούστευσης της αρχικής πληροφορίας που αναφέρεται στον Αριστοτέλη. Η θεμελιώδης αυτή φιλοσοφική θεώρηση υποστηρίζει την ελάττωση της αρχικής πληροφορίας σε διακριτά τμήματα, ώστε να διευκολυνθεί η μελέτη της. Σύμφωνα με αυτήν τη φιλοσοφική θεώρηση, στην παρούσα εργασία επιχειρείται να απομονωθεί ένα σύνολο τιμών που γεωμετρικά αποτελεί ένα γνήσιο υποσύνολο όλων των τιμών ενός συνόλου

ΗΕΓραφημάτων του ίδιου ατόμου. Προς αυτήν την κατεύθυνση θεωρείται ένα σύνολο  $n$  σημείων στο καρτεσιανό επίπεδο, έστω  $A = \{a_1, a_2, a_3, \dots, a_n\}$ . Αυτά τα σημεία, στην παρούσα εργασία, είναι τα χαρακτηριστικά διανύσματα που έχουν εξαχθεί από το στάδιο προ(επεξεργασίας) του ΗΕΓ και αποτελούνται είτε από τους συντελεστές AR είτε από τα πλάτη των φασματικών συνιστωσών του σήματος.

Σε οποιαδήποτε από τις δύο περιπτώσεις τα χαρακτηριστικά διανύσματα εξαγονται με τη μεθοδολογία που αναπτύχθηκε σε προηγούμενες παραγράφους. Στη συνέχεια ορίζεται ένα υποσύνολο σημείων  $X$ , επί του αρχικού συνόλου σημείων  $A$ , ( $X \subseteq A$ ), το οποίο καθορίζει τις κορυφές ενός κυρτού πολυγώνου  $P$  στο καρτεσιανό επίπεδο, έτσι ώστε η επιφάνεια του πολυγώνου  $P$  να περικλείει όλα τα  $n$  σημεία (τιμές) του διανύσματος ή διαφορετικά το κυρτό σύνολο των τιμών  $X$  οριοθετεί μία κυρτή επιφάνεια που μέσα σε αυτή κινούνται οι τιμές των χαρακτηριστικών ΗΕΓραφικών διανυσμάτων (σύνολο  $A$ ). Η οριοθέτηση αυτή είναι σημαντική, διότι το πολύγωνο καθορίζει μία κλειστή περιοχή στην οποία περικλείονται όλα τα χαρακτηριστικά σημεία του κάθε διανύσματος. Αν την ιδιότητα αυτή τη μεταφέρουμε στη σφαίρα της ασαφούς λογικής (fuzzy logic), τότε δύναται να θεωρηθεί ότι το σύνολο των κανονικοποιημένων σημείων  $A$ , τα οποία κινούνται εντός του διαστήματος  $[0,1]$ , απαρτίζει ένα κυρτό ασαφές σύνολο (convex fuzzy set), [126].

### **Ανάπτυξη αλγορίθμου κατασκευής κυρτού πολυγώνου.**

Στην παρούσα παράγραφο περιγράφονται τα βήματα που πρέπει να ακολουθηθούν, ώστε να υλοποιηθεί η πρόταση της προηγούμενης παραγράφου (3.4.4.1). Συγκεκριμένα, τα βήματα είναι τα ακόλουθα :

Κατασκευή κυρτού πολυγώνου από  $n$  σημεία στο καρτεσιανό επίπεδο. Το 1972 ο Graham, πρότεινε έναν αλγόριθμο πολυπλοκότητας  $O(n \log n)$ , ο οποίος υπολόγιζε το κυρτό κέλυφος από  $n$  δεδομένα σημεία στο Καρτεσιανό επίπεδο.

## **Τομή δύο κυρτών πολυγώνων**

Η επίλυση του προβλήματος υπολογισμού της τομής δύο ομοεπίπεδων κυρτών πολυγώνων επετεύχθη με τον αλγόριθμο του Shamos, 1975, ο οποίος σε γραμμικό χρόνο είχε υπολογιστική πολυπλοκότητα  $O(n)$ . Η επιτυχία αυτού του αλγορίθμου εξαρτάται από ένα προπαρασκευαστικό στάδιο, το οποίο καθορίζει κατά πόσον ένα δεδομένο σημείο βρίσκεται μέσα ή έξω από ένα γνωστό κυρτό επίπεδο πολύγωνο.

## **Υλοποίηση αλγορίθμων υπολογιστικής γεωμετρίας**

Για απλούστευση της παρουσίασης της μεθόδου, θεωρείται ότι τα ΗΕΓ διανύσματα ανήκουν στο δισδιάστατο χώρο και αποτελούνται από 10 τιμές (στοιχεία) έκαστο. Οι τιμές του κάθε διανύσματος θεωρούνται ότι προήλθαν από μία από τις προαναφερόμενες ηλεκτροεγκεφαλογραφικές μεθόδους επεξεργασίας. Η συνδυασμένη υλοποίηση των προαναφερόμενων αλγορίθμων υπολογιστικής γεωμετρίας περιγράφονται στα παρακάτω βήματα:

### **3.4 Μέθοδοι Προεπεξεργασίας**

Οι μέθοδοι προεπεξεργασίας έχουν σκοπό να απομονώσουν διάφορα χαρακτηριστικά τα οποία σχετίζονται με βιολογικούς δείκτες και τα οποία θα μας δώσουν χρήσιμα συμπεράσματα σχετικά με την πρόβλεψη της δυσκολίας που αισθάνεται ένα άτομο, όταν εκτελεί μια εκπαιδευτική διαδικασία.

#### **3.4.1 Μέθοδοι προεπεξεργασίας για την εξαγωγή στάσιμων ιδιοτήτων σημάτων**

Αρχικά απομονώνονται τα φασματικά μονομορφικά κύματα ρυθμού  $\alpha$ . Η επιλογή του χρονικού ορίζοντα για την εξαγωγή στάσιμων χαρακτηριστικών γίνεται με γνώμονα εμπειρικά πειραματικά δεδομένα [33], [99]. Στη συνέχεια, από τα χρονικά πλαίσια που έχουν επιλεγεί και ειδικότερα από το συνολικό φάσμα τους, απομονώνονται τα μονομορφικά κύματα ρυθμού  $\alpha$ .

Όπως είναι γνωστό, το HEΓ θεωρείται γενικά ένα μη στάσιμο σήμα [33]. Γι' αυτόν τον λόγο η επιλογή του απαραίτητου (μεταβαλλόμενου) μήκους τμήματος από το καταγεγραμμένο HEΓ, δύναται να δώσει στάσιμα χαρακτηριστικά, τα οποία είναι σημαντικά για τους σκοπούς της διατριβής. Σε προηγούμενες εργασίες άλλων ερευνητών χρονικά πλαίσια HEΓ 1-sec έχει αναφερθεί ότι προσεγγιστικά δίνουν στάσιμα χαρακτηριστικά. Η προτεινόμενη μέθοδος βασίζεται στην υπόθεση ότι η μορφή του σήματος ενός χρονικού πλαισίου HEΓ μπορεί να περιγραφεί από τον βαθμό ασυμμετρίας γύρω από ένα χαρακτηριστικό σημείο.

Έστω ότι έχει επιλεγεί κατά βέλτιστο τρόπο ένα συγκεκριμένο μήκος δειγμάτων (διάρκεια) του σήματος HEΓ, και με βάση αυτό το μήκος το αρχικό σήμα HEΓ έχει τεμαχιστεί σε τμήματα. Έστω  $X_k$  το  $k$ -στο τμήμα, όπου  $k$  ο δείκτης που αριθμεί τα τμήματα (segments),  $k = 1, 2, 3, \dots, L/2$ . Ο βαθμός ασυμμετρίας του  $X_k$  υπολογίζεται από το κριτήριο Pearson [127] και περιγράφεται πολύ αναλυτικά στο επόμενο κεφάλαιο.

### ***3.4.2 Μέθοδοι προεπεξεργασίας για την απαλοιφή της επίδρασης των προκλητών δυναμικών***

Στη συνέχεια της έρευνάς μας προχωρήσαμε ακόμα ένα βήμα. Αφαιρέσαμε αλγοριθμικά την επίδραση των προκλητών δυναμικών, με αποτέλεσμα να προκύψει ένα σήμα το οποίο προσιδιάζε σε απλό ηλεκτροεγκεφαλογράφημα. Η μέθοδος αφαίρεσης της επίδρασης των προκλητών δυναμικών ξεκίνησε με μια διαδικασία προεπεξεργασίας και ανάλυσης του σήματος.

Αρχικά λοιπόν επεξεργαστήκαμε το σήμα, ώστε να αφαιρέσουμε τα προκλητά δυναμικά. Στην αρχική του κατάσταση το σήμα χωρίζεται σε 100 εποχές (epochs), καθεμιά από τις οποίες περιλαμβάνει 100 γεγονότα (events) των 1000 σημείων περίπου. Με τη μέθοδο που περιγράφουμε ακριβώς παρακάτω αφαιρούμε την επίδραση των προκλητών δυναμικών.

Βρήκαμε ότι η εποχή με τα λιγότερα σημεία περιείχε 974 σημεία. Αυτήν την εποχή χρησιμοποιήσαμε ως βάση για τη φάση της προεπεξεργασίας. Στη φάση αυτή το πραγματικό ηλεκτροεγκεφαλικό σήμα απομονώθηκε από τα δεδομένα των προκλητών δυναμικών (Brain Evoked Potential Data - BEPD). Η διαδικασία που ακολουθήσαμε προκειμένου να απομονώσουμε αυτά τα δεδομένα ήταν η παρακάτω :

1. Το σήμα BEPD χωρίστηκε σε  $k$  τμήματα, σύμφωνα με τα 100 γεγονότα (events) που είχαμε.
2. Χρησιμοποιήσαμε ως πρότυπο (pattern) το μικρότερο σε μήκος τμήμα ανάμεσα σε δύο γεγονότα και απομονώσαμε  $n$  ίσα τμήματα των BEPD.
3. Αφαιρέσαμε τα πρώτα 74 σημεία τα οποία περιείχαν το ερέθισμα και έτσι έμειναν 900 σημεία για κάθε τμήμα.
4. Στη συνέχεια κάθε τμήμα υπέστη μετασχηματισμό FFT και από αυτό υπολογίσαμε την εικόνα και τα πραγματικά μέρη.
5. Έπειτα τα  $n$  ίσα BEPDs υπέστησαν τη διαδικασία averaging και έτσι προέκυψε τελικά ένα BEPD το οποίο ήταν και ο μέσος όρος των υπολοίπων.
6. Το averaged τμήμα BEPD υπέστη μετασχηματισμό FFT και από αυτό εξήχθη η πραγματική εικόνα και τα μέρη του.
7. Υπολογίσαμε τη διαφορά ανάμεσα στα αρχικά BEPDs και το averaged BEPD (real and image parts).
8. Έτσι προέκυψε το τελικό EEG για κάθε τμήμα το οποίο ήταν απαλλαγμένο από το προκλητό δυναμικό.

### **III. ΕΙΔΙΚΟ ΜΕΡΟΣ**





## 4. ΜΕΘΟΔΟΙ ΠΟΥ ΑΝΑΠΤΥΧΘΗΚΑΝ & ΜΑΘΗΜΑΤΙΚΟ ΥΠΟΒΑΘΡΟ

Στο παρόν κεφάλαιο παραθέτουμε τις μεθόδους που αναπτύξαμε για την πραγματοποίηση της έρευνάς μας. Επίσης αναφέρουμε όλα τα εργαλεία καθώς και το μαθηματικό υπόβαθρο και τις ψηφιακές τεχνικές ανάλυσης στα οποία βασιστήκαμε, προκειμένου να ολοκληρωθεί η εργασία μας.

### 4.1 Στάσιμα Σημεία

Σκοπός αυτής της έρευνας ήταν να αναγνωρίσει σταθερά σημεία και σταθερές κυματομορφές σε EEG σήματα. Γενικά, ένα ΗΕΓ σήμα είναι ένα πολυσύνθετο μη στάσιμο σήμα. Είναι πολύ δύσκολο να αναγνωριστούν ιδιαίτερα χαρακτηριστικά του, όπως βιομετρικά πρότυπα (biometric patterns) ή παθολογικές αλλοιώσεις. Χρησιμοποιώντας μια επαναλαμβανόμενη διαδικασία Αυτοσυσχέτισης και Συμμετρικά Χαρακτηριστικά του ηλεκτροεγκεφαλογραφήματος, το οποίο μπορεί να προσομοιασθεί και με μια χρονολογική σειρά, στην παρούσα εργασία διερευνώνται πειραματικά σταθερά σημεία που πιθανώς υπάρχουν σε EEG σήματα. Επίσης διερευνάται ο σχηματισμός ατράκτων στάσιμων κυμάτων γύρω από αυτά τα σταθερά σημεία, οι οποίες αποκαλύπτουν την ύπαρξη σταθερών κυματιδίων σήματος ΗΕΓ.

Στην παρούσα μελέτη διερευνήθηκαν τα συμμετρικά χαρακτηριστικά του ΗΕΓ, χρησιμοποιώντας μια καλά προσαρμοσμένη διαδικασία των Συντελεστών Αυτοσυσχέτισης (Auto Auto Correlation Coefficients – ACC). Ο αλγόριθμος αυτής της διαδικασίας οικοδομήθηκε στα ακόλουθα τρία βήματα :

1. ο υπολογισμός των Συντελεστών Αυτοσυσχέτισης (ACC), χρησιμοποιώντας συμμετρικά χαρακτηριστικά
2. η δημιουργία του Πολυωνύμου, εύρεση δηλαδή των συντελεστών του, με τη βοήθεια των ACC
3. η Γραφική Αναπαράσταση της Παρεμβολής

Η μέθοδος που ακολουθήσαμε :

### **A) ο Αλγόριθμος ACC**

Το σχήμα ενός τμήματος μιας Χρονολογικής Σειράς μπορεί να περιγραφεί από τον βαθμό ασυμμετρίας γύρω από ένα χαρακτηριστικό σημείο. Ο βαθμός ασυμμετρίας ενός τμήματος λαμβάνεται μέσω του κριτηρίου του Pearson [103] και περιγράφεται από την ακόλουθη εξίσωση (16) :

$$S = \frac{\bar{X} - M_0}{s} \quad (16)$$

Όπου :  $S$  είναι ο βαθμός ασυμμετρίας,

$\bar{X}$  είναι η μέση τιμή ενός τμήματος της χρονολογικής σειράς,

$M_0$  είναι η τιμή του χαρακτηριστικού σημείου της χρονολογικής σειράς (δεδομένα), το οποίο λαμβάνεται ως μέγιστη τιμή,

$s$  είναι η τυπική απόκλιση ενός τμήματος της χρονολογικής σειράς.

Ο βαθμός ασυμμετρίας μπορεί να χαρακτηριστεί ως ένας απαραίτητος και βασικός συντελεστής του τμήματος της χρονολογικής σειράς στην περίπτωση μας, επειδή απεικονίζει μια συνολική γεωμετρική εικόνα του τμήματος. Σ' αυτό το στάδιο, το τμήμα της χρονολογικής σειράς  $x_t$  υποβάλλεται σε ανάλυση πυκνότητας φασματικής ισχύος (power-spectral density analysis) κάθε αλληλεπικαλυπτόμενου τμήματος της χρονολογικής σειράς και υπολογίζεται χρησιμοποιώντας εκτίμηση της συχνότητας του πρότυπου περιοδογράμματος (frequency estimation of the standard periodogram), ως εξής:

$$S_x(f) = \frac{1}{T} \left| \sum_{t=1}^T x_t e^{j-2\pi f t} \right|^2 \quad (17)$$

Τα δείγματα  $x_t$  αντικαθίστανται από τα δείγματα του περιοδογράμματος, τα οποία δίνονται από τα  $|f_n|$  και τα οποία μπορούν να υπολογιστούν χρησιμοποιώντας τον αλγόριθμο Fast Fourier Transformation (FFT) [103]. Έτσι, σύμφωνα με την αντίστροφη συνάρτηση της εξίσωσης (16), παίρνουμε την ακόλουθη σχέση :

$$f_n = (S_n^{-1} (S_n f)) \quad (18)$$

Αυτή η προσέγγιση επίσης έχει εφαρμοστεί σε αρκετές περιπτώσεις, π.χ. ΗΕΓ μελέτες [96-103].

Χρησιμοποιώντας τις εξισώσεις (17) και (18), η εξίσωση (16) μετατρέπεται στην (19).

$$S_k = \frac{T \sqrt{T - 2(|\hat{f}| - |f_g|)}}{\sqrt{2T \sum_{k=1}^{T/2} f_n^2 - 4 \left( \sum_{k=1}^{T/2} f_n \right)^2}} \quad (19)$$

$$\text{όπου : } f_g = \max(f_n), \quad 1 \leq g \leq (\text{int}[T / 2])$$

Στη συνέχεια θεωρήθηκε ένα σύνολο ακολουθιών  $D$ , το οποίο αποτελείται από τους ακόλουθους συντελεστές :

$$\{D\} = \{\hat{D}_1, \hat{D}_2, \dots, \hat{D}_{k-1}\}$$

Όπου

$$\{\hat{D}_1\} = \{S_1, S_2\}, \quad \{\hat{D}_2\} = \{S_1, S_2, S_3\}$$

$$\{\hat{D}_3\} = \{S_1, S_2, S_3, S_4\}, \dots, \{\hat{D}_{k-1}\} = \{S_1, S_2, S_3, \dots, S_k\}$$

Τότε, οι ACC της προτεινόμενης μεθόδου υπολογίζονται ως εξής :

$$\hat{C} = [C_m] \quad (20)$$

όπου, το  $m = 3, \dots, k+2$  υπολογίζεται από τη σχέση (21), η οποία εκφράζει την αντίστοιχη συνάρτηση στάθμισης, χρησιμοποιώντας ένα παράθυρο πυκνότητας φασματικής ισχύος :

$$w_m = \text{int}\left(\frac{T}{m}\right), \quad w_m \geq 3 \quad (21)$$

Τότε, οι συντελεστές αυτοσυσχέτισης (ACC coefficients) δίνονται από την :

$$C_m = \sqrt{\frac{2k \sum_{m=1}^{k+2} (\hat{D}_k \hat{D}_k^T) - 4 \left| \sum_{m=1}^{k+2} (\hat{D}_k) \right|^2}{m(m-2)}} \quad (22)$$

## **B) Πολυώνυμο Παρεμβολής**

Στη συνέχεια υπολογίζουμε τους συντελεστές του βαθμού του πολυωνύμου  $p(x)$  (εξισώσεις 23-24). Προκειμένου να επιτευχθεί η καλύτερη προσαρμογή των  $p(x(i))$  στα  $C(i)$  χρησιμοποιείται η εξίσωση 24, όπου  $x(i)$  είναι τα στοιχεία του οριζόντιου άξονα (χρόνος ή σημεία) και  $C(i)$  είναι οι συντελεστές αυτοσυσχέτισης (ACC). Το παραγόμενο πολυώνυμο είναι γνωστό ως «Πολυωνυμική Παρεμβολή». Το αποτέλεσμα  $p$  είναι ένα διάνυσμα γραμμή μήκους  $n+1$  το οποίο περιέχει τους πολυωνυμικούς συντελεστές σε φθίνουσες δυνάμεις :

$$p(x) = p_1x^n + p_2x^{n-1} + \dots + p_nx + p_{n+1} \quad (23)$$

Στη συνέχεια, για να βρεθεί ακριβώς το γράφημα το οποίο ταιριάζει καλύτερα στους συντελεστές του πολυωνύμου παρεμβολής, για κάθε στοιχείο του οριζόντιου άξονα (x), υπολογίζεται το αντίστοιχο στοιχείο στον κάθετο άξονα (y), σύμφωνα με την εξίσωση

$$y = p_1x^n + p_2x^{n-1} + \dots + p_nx + p_{n+1} \quad (24)$$

όπου  $p_i$  είναι τα πολυώνυμα παρεμβολής που υπολογίσθηκαν προηγουμένως. Αυτό επιτυγχάνεται χρησιμοποιώντας την εκτίμηση delta error, στην οποία δέλτα είναι μια εκτίμηση της τυπικής απόκλισης του σφάλματος στην πρόβλεψη μελλοντικών παρατήρηση στο x από το  $p(x)$  (βλέπε εξίσωση 23).

#### 4.2 Συγχρονισμός Περιοδικών Ταλαντωτών

Στην παρούσα παράγραφο παρουσιάζουμε μια εντελώς νέα προσέγγιση της μέτρησης συγχρονισμού ενός μικρού συνόλου δεδομένων, χρησιμοποιώντας μια καινούρια τεχνική, σύμφωνα με την οποία δημιουργούμε μια διαδικασία σταθερής περιόδου για κάθε ένα από τα προς διερεύνηση μικρά διαδοχικά σύνολα δεδομένων, με τελικό σκοπό την αποκάλυψη στασιμότητας. Για να επιτευχθεί αυτό, χρησιμοποιούμε αρχικά έναν μετασχηματισμένο αλγόριθμο της περιγραφείσας εργασίας στην προηγούμενη παράγραφο. Ο σκοπός αυτού του τμήματος της εργασίας εστιάζεται στην ανάπτυξη νέων μεθοδολογιών εύρεσης στασιμότητας και στην εφαρμογή τους στα σημερινά προβλήματα συγχρονισμού, ειδικά της βραχυπρόθεσμης πρόβλεψης στις περιοχές της Βιοϊατρικής, Οικονομικών, Σεισμολογίας κ.τ.λ.. Η προτεινόμενη μέθοδος χωρίζεται στις τρεις ακόλουθες ενότητες: Στην πρώτη ενότητα υπολογίζεται ένα πρότυπο (pattern) πολυώνυμο παρεμβολής (όπως το κάναμε και στην προηγούμενη διαδικασία), για να χρησιμοποιηθεί για τον συντονισμό των τμημάτων τα οποία θα υποστούν μεταβολή φάσης. Στη συνέχεια επιλέγονται

τμήματα του σήματος (με συνεχείς μεταβολές των  $m$ ,  $k$  και  $n$  – μέγεθος παραθύρου, αριθμός τμημάτων και βαθμοί ελευθερίας πολυωνύμου αντίστοιχα), τα οποία, αφού υποστούν μια διαδικασία ανάλυσης παλινδρόμησης (regression analysis) και μεταβολή φάσης, συντονίζονται με το αρχικό πρότυπο (pattern). Το πειραματικό μέρος του αλγορίθμου υλοποιείται χρησιμοποιώντας ένα μικρό σύνολο δεδομένων EEG και παρουσιάζεται, στο τρίτο μέρος το οποίο ονομάζεται συγχρονισμός. Στο 6.2 αναλύονται τα συμπεράσματα του πειραματικού μέρους καθώς και ο μελλοντικός σχεδιασμός της παρούσας μεθόδου.

Η μέθοδος που ακολουθήσαμε :

Η διαδικασία αυτή χωρίζεται σε τρία επί μέρους τμήματα. Στην πρώτη υποενότητα, η οποία ονομάζεται «Συντελεστές Αυτο-Συσχέτισης» (Auto-Correlation Coefficients), χρησιμοποιείται η διαδικασία που περιγράψαμε στην παράγραφο 4.1. Στη δεύτερη υποενότητα, η οποία ονομάζεται «Σταθερές Διασταυρούμενες Καμπύλες» (Stable Cross Curves), διερευνάται αν μπορεί να λειτουργήσει ένας μηχανισμός ταιριάσματος των παραγόμενων πολυωνύμων παρεμβολής των τμημάτων του HEΓ με το pattern (γίνεται αλληπαλίζοντας αριθμός ταιριασμάτων μεταβάλλοντας πολλαπλά τα  $m$ ,  $k$  και  $n$ ). Τέλος, στην τρίτη υποενότητα, η οποία ονομάζεται «Συγχρονισμός» (Synchronization), παράγεται ένας αριθμός καμπυλών βασιζόμενος στα ταιριάσματα της  $2^{ns}$  υποενότητας.

### **A) Συντελεστές Αυτοσυσχέτισης (Auto-Correlation Coefficients - ACC)**

Η μελέτη αυτή βασίζεται στην υπόθεση ότι το σχήμα ενός τμήματος μιας χρονολογικής σειράς μπορεί να περιγραφεί με τον βαθμό της ασυμμετρίας γύρω από ένα χαρακτηριστικό σημείο. Ο βαθμός ασυμμετρίας ενός τμήματος λαμβάνεται από το κριτήριο Pearson [44] και περιγράφεται από την ακόλουθη εξίσωση (25) :

$$S = \frac{\vec{Y}_k - M_0}{S_k} \quad (25)$$

όπου :

Όπου : S είναι ο βαθμός ασυμμετρίας,

Y είναι η μέση τιμή ενός τμήματος της χρονολογικής σειράς,

M<sub>0</sub> είναι η τιμή του χαρακτηριστικού σημείου της χρονολογικής σειράς (δεδομένα), το οποίο λαμβάνεται ως μέγιστη τιμή,

s είναι η τυπική απόκλιση ενός τμήματος της χρονολογικής σειράς,

k είναι ο δεδομένος αριθμός του συνόλου δεδομένων που είναι πολλαπλάσιο των αριθμών (2-9) με  $2 \leq k \leq 81$ .

Το εύρος του k υποδεικνύει ένα μικρό σύνολο δεδομένων. Ο βαθμός ασυμμετρίας μπορεί να χαρακτηρίζεται ως ένας απαραίτητος χαρακτηριστικός συντελεστής του τμήματος της χρονολογικής σειράς. Ο βαθμός ασυμμετρίας είναι ένα «γεωμετρικό χαρακτηριστικό».

Εν συνεχεία, θεωρήσαμε ένα σύνολο C ακολουθιών, το οποίο αποτελείται από τους ακόλουθους συντελεστές :

$$\{C\} = \begin{bmatrix} \{D_1\} = \{1^k | S\}, \\ \{D_2\} = \{1^{k/2} | S, {}^k_{k/2} | S\}, \\ \{D_3\} = \{1^{k/9} | S, {}^{2k/9}_{k/9} | S, {}^k_{2k/9} | S\}, \\ \dots \\ \{D_m\} = \{1^{k/n} | S, {}^{2k/n}_{k/n} | S, \dots, {}^k_{k/q+n} | S\} \end{bmatrix} \quad (26)$$

Όπου :

$$n = 1, 2, \dots, 9 \quad \text{και} \quad k - n \times q = n \quad (27)$$

Σε περισσότερες λεπτομέρειες, αυτή η αλληλουχία αποτελείται από μια αριθμητική εξέλιξη στην οποία ο συνολικός αριθμός των ACC δίνεται από η γνωστή εξίσωση Gauss (βλέπε εξίσωση 28)

$$m = \frac{(1+q) \times q}{2} \quad (28)$$

Στη συνέχεια, το παραγόμενο ACC απεικονίζεται ως διάνυσμα και δίνεται από την ακόλουθη εξίσωση:

$$\{\vec{C}_m\} = [\{D_1\}, \{D_2\}, \dots, \{D_m\}] \quad (29)$$

Μια μη γραμμική σχέση μεταξύ της τιμής του  $x$  η οποία αντιστοιχεί στα σημεία του οριζόντιου άξονα (χρόνος ή σημεία) και το αντίστοιχο  $C_m$ , δηλώνεται ως σχέση  $(C_m - x)$  σχέση. Το παραγόμενο πολυώνυμο είναι γνωστό ως «Πολυωνυμική Παρεμβολή» (Interpolation Polynomial). Το αποτέλεσμα  $p$  είναι ένα διάνυσμα γραμμή μήκους  $m$ , που περιέχει τους πολυωνυμικούς συντελεστές κατά φθίνουσα δύναμη :

$$p(x) = p_1 x^m + p_2 x^{m-1} + \dots + p_{m-1} x + p_m \quad (30)$$

Η δήλωση ότι το  $p$  παρεμβάλλει τα σημεία δεδομένων σημαίνει ότι

$$P(x_i) = C_i, \quad i \in \{1, \dots, m\}$$

Η επίλυση του συστήματος των γραμμικών εξισώσεων (31) δίνει τους συντελεστές που εμφανίζονται στην εξίσωση (31)



$$\vec{p} = \begin{bmatrix} p_m \\ \dots \\ p_1 \end{bmatrix} = \frac{\begin{bmatrix} x_1^m & \dots & x_1 & 1 \\ \dots & \dots & \dots & \dots \\ \dots & \dots & \dots & \dots \\ x_m^m & \dots & x_m & 1 \end{bmatrix}}{\begin{bmatrix} D_1 \\ \dots \\ D_m \end{bmatrix}} \quad (31)$$

Στη συνέχεια δημιουργούμε ένα διάνυσμα γραμμή  $D_N$  γραμμικά ισοδύναμα χωρικά σημεία μεταξύ  $x_1$  και  $x_m$ , προκειμένου να κατασκευαστούν καλά ταιριασμένες καμπύλες γύρω από τα σημεία  $m$ . Στη συνέχεια χρησιμοποιώντας το σφάλμα πρόβλεψης εκτιμάται η συνάρτηση DELTA [83], η οποία είναι η τυπική απόκλιση του σφάλματος στην πρόβλεψη μιας μελλοντικής παρατήρησης και στη συνέχεια υπολογίζουμε τους συντελεστές  $D_N$  σύμφωνα με την εξίσωση (32) :

$$\vec{D}_N = \frac{1}{N \times \log\left(\frac{x_N}{N}\right) + 1} \quad (32)$$

Έτσι η εξίσωση (30) μετασχηματίζεται στην ακόλουθη προσεγγιστική εξίσωση (33) :

$$p(x) = p'_1 x^m + p'_2 x^{m-1} + \dots + p'_{m-1} x + p'_m \quad (33)$$

όπου :

$$\|p_m = p'_m\| \leq \varepsilon$$

## **Β) Σταθερές Διασταυρούμενες Καμπύλες (Stable Cross Curves)**

Έχοντας υπόψη, από τη μια μεριά προηγούμενες πολύ γνωστές μελέτες [80] στις οποίες ο Neugebauer έδειξε ότι οι μετασχηματισμοί Backlund μπορούν να χρησιμοποιηθούν, για να παράγουν συμμετρικά βαρυτικά πεδία στάσιμου άξονα με οποιοδήποτε αριθμό σταθερών και από την άλλη πλευρά τον πειραματισμό μας, συμπεραίνονται φτάνουμε στην ακόλουθη πρόταση :

$$p'_1(x_t) = p'_2(x_t) = \dots = p'_w(x_t) \quad (34)$$

Με την προϋπόθεση ότι η συνάρτηση έχει σταθερές τις παραμέτρους  $n$  (βαθμός πολυωνύμου),  $m$  (παράθυρο) και  $k$  (πλήθος τμημάτων σήματος). Στη συνέχεια, γύρω από τα σημεία δημιουργούνται σταθερές συνθήκες, όταν υπάρχουν διασταυρούμενες καμπύλες.

## **Γ) Συγχρονισμός (Synchronization)**

Στη συνέχεια, τα  $x_t$  σταθερά σημεία δημιουργούν σταθερές περιόδους γύρω τους. Ο συγχρονισμός των καμπυλών ζεύγους ανιχνεύεται, όταν η τυπική απόκλιση των διαφορών ζεύγη καμπυλών ελαχιστοποιείται (βλέπε εξίσωση 35)

$$\sigma = \sqrt{E\left[\{(p'_w - p'_{w-1}) - \mu\}^2\right]} \leq \partial \quad (35)$$

όπου :

$$E[(p'_w - p'_{w-1})] = \mu \quad \text{με μέση τιμή } \mu \quad (36)$$

#### 4.3 Ταξινόμηση και Κατηγοριοποίησης Δεικτών

Σε αυτό το μέρος της έρευνάς μας μελετήσαμε νευροφυσιολογικούς (ή ηλεκτροφυσιολογικούς) δείκτες, με σκοπό να ανακαλύψουμε κάποιο μοντέλο το οποίο θα μπορεί να προβλέπει με μεγάλη ακρίβεια τη δυσκολία που μπορεί να αισθάνεται κάποιο άτομο κατά τη διάρκεια μιας εκπαιδευτικής διαδικασίας. Μέσα από την εργασία μας, αναλύσαμε αρκετούς δείκτες και καταφέραμε να απομονώσουμε αλγόριθμους με πολύ καλές αποδόσεις στην πρόβλεψη και έτσι καταφέραμε να φτιάξουμε ένα μοντέλο που συνδυάζει αυτούς τους δείκτες. Πιο συγκεκριμένα χρησιμοποιήσαμε τους δείκτες ERPs, ERSs, ITCs, Φασματική Ισχύ (Power Spectra), και τέλος έναν πολύ σημαντικό δείκτη, τον Global Field Power (GFP). Ο GFP είναι ένας δείκτης ο οποίος αντιπροσωπεύει τη χωρική τυπική απόκλιση των προκλητών δυναμικών στον χάρτη του εγκεφάλου. Στη συνέχεια χρησιμοποιήσαμε μεθόδους ταξινόμησης – κατηγοριοποίησης, έτσι ώστε να βρούμε κατάλληλα μαθηματικά μοντέλα πρόβλεψης της δυσκολίας στην εκπαιδευτική διαδικασία.

Η εκπαιδευτική διαδικασία η οποία χρησιμοποιείται σε αυτήν την εργασία είναι η αναγνώριση μιας εικόνας, η οποία είναι μπερδεμένη μαζί με άλλες σε μια φωτογραφία. Τα άτομα καλούνται, μετά από μικρή εκπαίδευση, να αναγνωρίσουν την εικόνα αυτή και να απαντήσουν θετικά ή αρνητικά. Πιο συγκεκριμένα τα άτομα καλούνται να αναγνωρίσουν κάποιο ζώο μέσα σε μια εικόνα. Το ζώο αυτό βρίσκεται μεταξύ άλλων πλασμάτων και αντικειμένων. Έτσι σε κάποιες εικόνες είναι εύκολο να αναγνωρισθεί και σε κάποιες είναι δύσκολο. Στόχος μας είναι να μελετήσουμε την αντίδραση του εγκεφάλου μέσα από την καταγραφή και την ανάλυση του ηλεκτροεγκεφαλογραφήματος. Μετά από τη μελέτη της αντίδρασης του εγκεφάλου, διερευνούμε την ύπαρξη ορισμένων χαρακτηριστικών, τα οποία είναι ικανά να περιγράψουν αυτήν την κλιμακωτή δυσκολία ανίχνευσης (προσδιορισμού) της συγκεκριμένη εικόνας του ζώου, μεταξύ άλλων θεμάτων της εικόνας.

Κατά την ανάλυση του σήματος EEG, απομονώσαμε αρκετούς νευροφυσιολογικούς (ή ηλεκτροφυσιολογικούς) δείκτες. Μέσα από διάφορους αλγόριθμους κατηγοριοποίησης (ταξινόμησης) καταφέραμε να απομονώσουμε αυτούς τους δείκτες που είναι ικανοί για την πιθανή πρόβλεψη της δυσκολίας που αισθάνεται ένα άτομο κατά την εκτέλεση μιας εκπαιδευτικής διαδικασίας.

#### Μεθοδολογία Έρευνας

Όπως ήδη έχουμε αναφέρει στο τμήμα αυτό της έρευνάς μας, διερευνήσαμε τον τρόπο αντίδρασης του ανθρώπινου εγκεφάλου σε εκπαιδευτικά ερεθίσματα διαφορετικής δυσκολίας και κατανόησης. Πιο συγκεκριμένα, από τη μελέτη της εγκεφαλικής αντίδρασης διερευνήθηκε η ύπαρξη δεικτών (features), οι οποίοι είναι ικανοί να περιγράψουν την κλιμακούμενη δυσκολία ανεύρεσης μια εικόνας. Μέσα από την επεξεργασία των ηλεκτροεγκεφαλογραφημάτων, απομονώσαμε διάφορους νευροφυσιολογικούς δείκτες, τους οποίους μέσα από αλγόριθμους ταξινόμησης μπορέσαμε να απομονώσουμε ως κατάλληλους για την πρόβλεψη της δυσκολίας που έχει κάποιο υποκείμενο την ώρα που εκτελεί μια εκπαιδευτική διαδικασία.

Η παρούσα μελέτη αφορά φυσιολογικά άτομα και ως μέσο έρευνας της εγκεφαλικής αντίδρασης χρησιμοποιήθηκε το ηλεκτροεγκεφαλογράφημα (ΗΕΓ). Στους συμμετέχοντες της παρούσας έρευνας δόθηκαν ως εκπαιδευτικά ερεθίσματα οι ακόλουθες εκπαιδευτικές πράξεις: i) εύκολη αναγνώριση μιας μορφής ζώου μέσα σε μια εικόνα και ii) δύσκολη αναγνώριση μιας μορφής ζώου μέσα σε μια εικόνα. Έπειτα από τις ηλεκτροεγκεφαλικές (ΗΕΓ) καταγραφές εξάχθηκε ένας μεγάλος αριθμός νευροφυσιολογικών δεικτών και με την χρήση αλγορίθμων και τεχνικών εξόρυξης γνώσης επιλέχθηκαν οι δείκτες που είναι ικανοί να περιγράψουν καλύτερα την διαφοροποίηση της εγκεφαλικής αντίδρασης σε αυτές τις εκπαιδευτικές δραστηριότητες κλιμακωτής δυσκολίας. Στην τελική φάση, τα διανύσματα που προέκυψαν εισάχθηκαν σε ένα περιβάλλον εξόρυξης γνώσης και αξιολόγησης, στο οποίο τελικά

χρησιμοποιήθηκε ένας μεγάλος αριθμός αλγόριθμων-ταξινομητών, ώστε να προκύψει το καλύτερο μοντέλο πρόβλεψης. Οι δείκτες περιγράφονται στην παράγραφο [4.3.1], ενώ το περιβάλλον εξόρυξης γνώσης και αξιολόγησης των διανυσμάτων των δεικτών περιγράφεται στην παράγραφο [5.5.4].

#### **4.3.1 Οι Νευροφυσιολογικοί Δείκτες που μελετήθηκαν**

Οι Δείκτες (indexes) που μελετήθηκαν στην παρούσα εργασία, προκειμένου να εξαχθούν συμπεράσματα μέσω των διανυσμάτων δεικτών (index vectors) τους για την ενδεχόμενη συσχέτισή τους με τη δυσκολία του μαθηματικού προβλήματος, είναι :

- Προκλητά Δυναμικά (Evoked Related Potential – ERPs)
- Φασματικές Διαταραχές σχετικές με το γεγονός (Event Related Spectral Perturbation – ERSPs)
- Inter Trial Coherence - ITCs
- Global Field Power - GFPs
- Φασματική Ισχύς Σήματος (Power Spectral)

Πρέπει να αναφέρουμε ότι όλα τα πειράματα έγιναν με το toolbox EEGLAB του matlab [152].

#### **4.3.2 Global Field Power (GFP)**

Ένας πολύ σημαντικός δείκτης στη μελέτη ηλεκτροεγκεφαλογραφημάτων είναι ο «Global Field Power (GFP)» [60], ο οποίος προκύπτει από επεξεργασία ηλεκτροεγκεφαλογραφικών ERPs (Event Related Potentials).

Ο δείκτης Global Field Power [60],[91],[112],[151] είναι εργαλείο ποσοτικής ανάλυσης, με το οποίο προσδιορίζεται το σύνολο της δραστηριότητας σε ένα δεδομένο δυναμικό του πεδίου το οποίο αποτελεί το τριχωτό της κεφαλής, και έχει προταθεί στο [59].

Οι καμπύλες των δυναμικών του πεδίου του τριχωτού της κεφαλής, οι οποίες παρουσιάζουν απότομες κλίσεις και έντονες κορυφές και ακμές, οδηγούν σε μεγάλες τιμές GFP, ενώ αντίθετα μικρές τιμές του δείκτη εμφανίζονται σε μικρές κλίσεις καμπύλης δυναμικού.

Το GFP είναι μέτρο της έντασης ενεργοποίησης (strength of activation) σε μια δεδομένη χρονική στιγμή. Επίσης αποτελεί τη χωρική τυπική απόκλιση των τιμών της καμπύλης του δυναμικού (εννοείται πως τα ηλεκτρόδια έχουν κοινή αναφορά).

Ο Global Field Power υπολογίζεται από την εξίσωση (37) και απεικονίζει τη χωρική τυπική απόκλιση (spatial standard deviation) στο πλαίσιο κάθε χάρτη εγκεφάλου (brain map) σε μια δεδομένη στιγμή [60].

$$GFP = \sqrt{\frac{1}{2n^2} \sum_{i=1}^n \sum_{j=1}^n (U_i - U_j)^2} \quad (37)$$


Όπου  $U_i$  και  $U_j$  είναι τα μετρήσιμα προκλητά δυναμικά και  $n$  είναι ο αριθμός των ατόμων που εξετάστηκαν (στην περίπτωσή μας 14). Ο δείκτης GFP χρησιμοποιείται ως εργαλείο ποσοτικής ανάλυσης, για να προσδιοριστεί το σύνολο της δραστηριότητας σε ένα συγκεκριμένο τομέα δυναμικού του εγκεφάλου. Υπολογίζεται από τον μέσο όρο όλων των πιθανών διαφορών δυναμικού στο πεδίο [59] και [112].

Αυτό αντιστοιχεί με την τυπική απόκλιση όλων των ηλεκτροδίων καταγραφής σε σχέση με τη μέση αναφορά. Στην εργασία μας, τα δεδομένα που χρησιμοποιήσαμε ήταν Αφιλτράριστα Πολυκαναλικά Δεδομένα Εγκεφαλικών Προκλητών Δυναμικών από φυσιολογικά άτομα. Το σενάριο ήταν το εξής : τα άτομα έπρεπε να αναγνωρίσουν ζώα μεταξύ άλλων αντικειμένων σε διάφορες εικόνες. Υπήρχαν εικόνες, στις οποίες τα ζώα αναγνωρίζονταν ευκολότερα και σε κάποιες άλλες, όπου τα ζώα αναγνωρίζονταν δυσκολότερα. Στη συνέχεια, από

τις ηλεκτροεγκεφαλικές καταγραφές εξήχθησαν χαρακτηριστικά διανύσματα (οι δείκτες). Από την εμπεριστατωμένη πολύμηνη έρευνα από τους δείκτες που περιγράψαμε προηγουμένως και τους οποίους περιγράψαμε αναλυτικά, τελικά καταλήξαμε σε τρεις επικρατέστερους ως καλύτερους. Τους GFP, ERSP και PS. Μετά από τη μελέτη των δεικτών, χρησιμοποιώντας αλγόριθμους και τεχνικές εξόρυξης δεδομένων, επιλέξαμε ταξινομητές που ήταν ικανοί να περιγράψουν ικανοποιητικά τη διαφοροποίηση των εγκεφαλικών αντιδράσεων στα διάφορα εκπαιδευτικά προβλήματα με τη μεταβλητή δυσκολία. Πιο συγκεκριμένα, χρησιμοποιήσαμε κατάλληλο λογισμικό εξόρυξης και αξιολόγησης γνώσης, (WEKA [162]), το οποίο περιλαμβάνει διάφορους αλγόριθμους ταξινόμησης. Με αυτήν τη διαδικασία λοιπόν εξάγαμε μαθηματικά μοντέλα που μπορούσαν να περιγράψουν πολύ ικανοποιητικά τη δυσκολία που συναντούν τα άτομα κατά την εκπαιδευτική διαδικασία. Κατ' επέκταση τα μοντέλα μπορούν να χρησιμοποιηθούν για την αναγνώριση και την πρόβλεψη των δυσκολιών που συναντούν τα άτομα σε μια εκπαιδευτική διαδικασία. Τέλος βελτιστοποιήσαμε τα μοντέλα μας με δύο τρόπους. Πρώτα με τη μεικτή μέθοδο ανάλυσης διακύμανσης (ANOVA) και στη συνέχεια με βελτιστοποίηση της δυνατότητας πρόβλεψης του μοντέλου με περιορισμό του αριθμού καναλιών.

Όπως αναφέρεται στο [59], ο δείκτης (ή μετρητής, όπως αλλιώς αναφέρεται) κατουσία, υπολογίζεται ως ο μέσος όρος όλων των δυνατών διαφορών δυναμικού του πεδίου (του τριχωτού της κεφαλής) και αντιστοιχεί στην τυπική απόκλιση (standard deviation) όλων των ηλεκτροδίων εγγραφής, σε σχέση με το μέσο όρο αναφοράς.

Στην ακόλουθη εικόνα φαίνεται το διάγραμμα του δείκτη GFP που υπολογίσαμε, για παράδειγμα για το κανάλι 10 και όλα τα tasks του συγκεκριμένου trial.




**Εικόνα 19:** Ο δείκτης GFP για το κανάλι 10 ενός ατόμου. Με κόκκινο η καταγραφή του ατόμου που εκτελεί τη δύσκολη εκπαιδευτική διαδικασία και με μπλε η καταγραφή του ατόμου που εκτελεί την εύκολη εκπαιδευτική διαδικασία

#### **4.3.3 Προκλητά Δυναμικά (Event Related Potential - ERPs)**

Το ηλεκτροεγκεφαλογράφημα, όπως είπαμε στα προηγούμενα, είναι καταγραφή της αυθόρμητης ηλεκτρικής ρυθμικής ταλάντωση του εγκεφάλου, όταν βρίσκεται σε ηρεμία και δεν δέχεται εξωτερικά ερεθίσματα. Τα τελευταία χρόνια ιδιαίτερα μεγάλης σημασίας [67],[29], [64],[110] είναι η καταγραφή δυναμικών τα οποία προκαλούνται από συγκεκριμένα γεγονότα. Τα δυναμικά αυτά ονομάζονται Δυναμικά Σχετικά με το Γεγονός (ERP - Event Related Potential) ή Προκλητά Δυναμικά.





**Εικόνα 20:** Διάγραμμα ERP με κορυφώσεις Αρνητικές (N - Negative) και Θετικές (P - Positive)

Τα Προκλητά Δυναμικά (Π.Δ.), ανάλογα με το είδος του εξωτερικού ερεθίσματος που τα προκαλεί, διακρίνονται σε [67],[29] :

- Οπτικά Π.Δ. (Visual Evoked Potentials, VEP): Όταν τα ερεθίσματα σχετίζονται με την όραση, όπως η εμφάνιση εικόνων, λάμπσεις, αλλαγές χρωμάτων κ.τ.λ.
- Ακουστικά Π.Δ. (Auditory Evoked Potentials, AEP): Όταν τα ερεθίσματα σχετίζονται με την ακοή, όπως εκφώνηση κάποιων λέξεων ή φράσεων, ήχοι με ένταση, όπως κουδουνίσματα ή κρότοι, εναλλαγή ήχητικών σημάτων διαφορετικών συχνοτήτων, έντασης και διάρκειας.
- Σωματοαισθητικά Π.Δ. (Somatosensory Evoked Potentials, SEP): Τα εξωτερικά ερεθίσματα είναι μικρής διάρκειας και έντασης ηλεκτρικά ρεύματα που ερεθίζουν κάποια συγκεκριμένα νεύρα.

Ένα από τα χαρακτηριστικά μεγέθη [64],[110] των Προκλητών Δυναμικών είναι ο Λανθάνων Χρόνος (Latency Time), ο οποίος είναι ο χρόνος εμφάνισής τους σε σχέση με τη στιγμή την οποία έγινε το εξωτερικό ερέθισμα (stimulus). Τα ακουστικά Π.Δ. διακρίνονται σε πρώιμα (early) (2-12 msec από τη στιγμή του

ερεθίσματος), μέσα (middle) (12-50 msec) και αργά ή ύστερα (late) (50-800 msec). Εύκολα μπορεί κανείς να παρατηρήσει πως το εύρος ζώνης των κυματομορφών μειώνεται, ενώ το πλάτος αυξάνεται, καθώς αυξάνει ο λανθάνων χρόνος [132]. Οι διαφοροποιήσεις αυτές στο εύρος ζώνης και το πλάτος οφείλονται στο σημείο έκλυσης των δυναμικών μέσα στον ανθρώπινο εγκέφαλο. Συγκεκριμένα, τα πρώιμα σχετίζονται με την διαβίβαση των νευρωνικών ώσεων κατά μήκος του ακουστικού ή οπτικού νεύρου για ακουστικά ή οπτικά προκλητά δυναμικά και κατά μήκος της σωματοαισθητικής οδού για τα σωματοαισθητικά. Αντίθετα τα ύστερα δυναμικά αντανακλούν την εγκεφαλική δραστηριότητα περιοχών του φλοιού ως αντίδραση στην άφιξη της εξωτερικής πληροφορίας.

Τα Π.Δ. διαχωρίζονται επίσης σε εξωγενή και ενδογενή, ανάλογα με το πώς σχετίζονται με το εξωτερικό ερέθισμα [64]. Τα εξωγενή έχουν να κάνουν με τη φύση του εξωτερικού ερεθίσματος (ένταση, συχνότητα κ.τ.λ.) και σχετίζονται με την ακεραιότητα των αισθητηριακών οδών. Παρατηρούνται σε χρόνο μικρότερο των 100msec από την παραγωγή του ερεθίσματος. Αντίθετα τα ενδογενή έχουν τη βάση τους στην ψυχολογική επίδραση του εξωτερικού ερεθίσματος στον άνθρωπο, καθώς σχετίζονται με διάφορα στάδια νοητικής επεξεργασίας των εξωτερικών ερεθισμάτων στο Κεντρικό Νευρικό Σύστημα (ΚΝΣ). Παρατηρούνται σε χρόνο μεγαλύτερο των 70msec. Αλλάζουν ανάλογα με το αν το ερέθισμα είναι γνωστό ή άγνωστο, αν είναι δυσάρεστο ή ευχάριστο, αν θυμίζει στον εξεταζόμενο μία προγενέστερη προσωπική του εμπειρία κ.τ.λ..

Η μελέτη και η αξιολόγηση των προκλητών δυναμικών γίνεται μελετώντας συγκεκριμένα σημεία των διαγραμμάτων των κυματομορφών. Από τη μελέτη αυτών των σημείων μπορούν να βγούν πολύτιμα συμπεράσματα. Τέτοια σημεία είναι :

- Εκεί όπου παρουσιάζονται κορυφώσεις του πλάτους
- το χρονικό εύρος της κυματομορφής που περιλαμβάνει την κορύφωση

Τα προκλητά δυναμικά (ERP) εμφανίζονται, όταν ο εγκέφαλος κάνει κάποιες συγκεκριμένες λειτουργίες. Ανάλογα με τις λειτουργίες αυτές, εμφανίζεται ένα συγκεκριμένο δυναμικό. Έτσι λοιπόν τα προκλητά δυναμικά ποικίλλουν. Υπάρχουν τα θετικά και τα αρνητικά δυναμικά (*Εικόνα 20*). Αυτά που παρουσιάζουν θετική μεταβολή στη διαφορά δυναμικού τους από την κατάσταση ηρεμίας τα συμβολίζουμε με P (positive) και έναν αριθμό. Αυτά που παρουσιάζουν αρνητική διαφορά δυναμικού από την κατάσταση μη εμφάνισής τους τα συμβολίζουμε με N (negative) και έναν αριθμό. Ο χρόνος στον οριζόντιο άξονα εκφράζει το λανθάνοντα χρόνο (latency time) εμφάνισης της κορυφής σε msec. Όπως είδαμε προηγουμένως. Με τον λανθάνοντα χρόνο, εννοούμε, τον χρόνο που περνά από τη στιγμή που συμβαίνει το ερέθισμα, έως τη στιγμή που συμβαίνει η κορύφωση. Στην (*Εικόνα 20*) μπορούμε να διακρίνουμε τις κορυφώσεις P100 (ή P1) , P200 (ή P2) , N100 (ή N1), N200 (ή N2). Αυτά αντιπροσωπεύουν τις πρώτες κορυφές (θετικές και αρνητικές) της κυματομορφής που παρουσιάζεται κατά την εμφάνιση ενός δυναμικού. Τα P1 και P2 είναι η πρώτη και η δεύτερη θετική κορυφή αντιστοίχως. Τα N1 και N2 αντιπροσωπεύουν την πρώτη και δεύτερη αρνητική κορυφή αντίστοιχα. Στα επόμενα, θα αναφερθούμε σε συγκεκριμένες κορυφώσεις, οι οποίες εμφανίζονται στα διαγράμματα των κυματομορφών των Προκλητών Δυναμικών (ERPs) και έχουν συγκεκριμένο λόγο και εξήγηση. Η εμφάνιση κάθε κυματομορφής σχετίζεται με διαφορετικές εγκεφαλικές διεργασίες [29][64][132][139]:

- P50 : θεωρείται ο δείκτης των προσυνειδητών πτυχών προσοχής και αντικατοπτρίζει τη μετάβαση των πληροφοριών από τον θάλαμο στα φλοιώδη προβλητικά πεδία. Περιγράφει τη θετική κορύφωση του μετρούμενου δυναμικού που εντοπίζεται στο χρονικό παράθυρο από 20 έως 80 msec μετά το ερέθισμα.
- N100: θεωρείται ο δείκτης επιλεκτικής προσοχής. Αντικατοπτρίζει την κατανομή των πληροφοριών στα κατάλληλα συνειρμικά πεδία. Πρόκειται για την αρνητική κορύφωση του μετρούμενου δυναμικού που εντοπίζεται στο χρονικό παράθυρο 90 ως 150 msec μετά την παρουσίαση

του ερεθίσματος. Ο λανθάνων χρόνος αντικατοπτρίζει την ταχύτητα κινητοποίησης της προσοχής, ενώ το μέγιστο πλάτος αντικατοπτρίζει την ικανότητα ή χωρητικότητα της προσοχής. Γενικά το κύμα N100 έχει μικρό ύψος ή και παρατεταμένο λανθάνοντα χρόνο, σε περίπτωση διάσπασης της προσοχής. Μεταβολές του κύματος N100 έχουν παρατηρηθεί σε άτομα που πάσχουν από κατάθλιψη, μεταβολές οι οποίες προφανώς σχετίζονται με κάποιο βαθμό διάσπασης της προσοχής την οποία εμφανίζουν οι καταθλιπτικοί ασθενείς. Μικρό ύψος του κύματος του N100 έχει παρατηρηθεί και σε άτομα τα οποία πάσχουν από το σύνδρομο Gilles de la Tourette.

- P200: θεωρείται ο δείκτης επικέντρωσης της προσοχής αναφορικά με τις επεξεργαζόμενες πληροφορίες. Περιγράφει τη θετική κορύφωση του μετρούμενου δυναμικού που εντοπίζεται από 140 ως 250 msec μετά το ερέθισμα.
- N200: θεωρείται ότι περιγράφει την αρνητική κορύφωση του μετρούμενου δυναμικού που εντοπίζεται από 180 ως 300 msec μετά το ερέθισμα. Αντικατοπτρίζει τις νευρωνικές επιδόσεις που υπόκεινται στο φαινόμενο της αντίδρασης του προσανατολισμού σε επίπεδο ΚΝΣ. Καταγράφεται μετά από μεσοποίηση των ήχων στις ίδιες με το P300 περιοχές και από ορισμένους μελετάται σαν σύμπλεγμα N200-P300. Το N200 μερικές φορές παρουσιάζει δικορυφία. Η πρώτη κορυφή, η N200a, της οποίας το μέγιστο ύψος καταγράφεται από τις βρεγματοϊνιακές περιοχές, θεωρείται εξωγενής. Αντίθετα η δεύτερη, η N200b, καταγράφεται χρονικά αργότερα με το ηλεκτρόδιο Cz και σχετίζεται με τον βαθμό προσοχής και τη δυσκολία κατηγοριοποίησης του ερεθίσματος. Ένας παράγοντας που επιδρά στη δημιουργία του N200 είναι το χρονικό διάστημα μεταξύ δυο διαδοχικών ερεθισμάτων. Συγκεκριμένα όσο μεγαλύτερη είναι η χρονική απόσταση ανάμεσα σε δυο διαδοχικά ερεθίσματα, τόσο μικρότερο είναι το ύψος του N200 και πιο παρατεταμένος ο λανθάνων χρόνος του.
- P300: θεωρείται ο δείκτης κινητοποίησης προγραμματών δράσης σε επίπεδο κεντρικού νευρικού συστήματος. Περιγράφει τη θετική

κορύφωση του μετρούμενου δυναμικού που εντοπίζεται από 220 ως 500 msec μετά το ερέθισμα. Ο λανθάνων χρόνος εμφάνισής του φαίνεται να αντανακλά το απαραίτητο χρονικό διάστημα, για να πάρει ο εξεταζόμενος μια απόφαση για το ερέθισμα. Ορισμένες φορές το P300 είναι δικόρυφο, γι' αυτό και διατυπώνεται η άποψη ότι δεν είναι απλά μια κυματομορφή, αλλά ένα σύμπλεγμα περισσότερων επιμέρους κυματομορφών. Το P300 θεωρείται ότι συνίσταται από τρεις επιμέρους κυματομορφές, το κύμα P3a, το κύμα P3b και το βραδύ κύμα (slow wave). Από τις κυματομορφές που αναφέρθηκαν το κύμα P3b είναι αυτό που ταυτίζεται συνήθως με το P300, γιατί σχετίζεται με τη συνειδητή επεξεργασία της πληροφορίας και απαιτεί την προσοχή του εξεταζόμενου. Γενικά το P300 είναι ένα από τα δημοφιλέστερα δυναμικά και χρησιμοποιείται ως νευροφυσιολογικός δείκτης των γνωσιακών διαδικασιών ενός εξεταζόμενου. Κλινικά, δηλαδή, μπορεί να αποτελέσει μια προσπάθεια εκτίμησης της ετοιμότητας των πνευματικών εγκεφαλικών λειτουργιών ενός ατόμου, γιατί αποτελεί τον πλέον ευαίσθητο δείκτη διαταραχής των γνωσιακών διαδικασιών. Όμως πρέπει να γίνει κατανοητό ότι το P300 δεν είναι σε καμία περίπτωση δείκτης εγκεφαλικής πάθησης, διότι έχει παρατηρηθεί να διατηρεί μια ομοιομορφία, κατά την καταγραφή του από άτομα υγιή και άτομα με κάποια πάθηση.

- N400: Αναγνωρίζεται ως ο δείκτης σημαντικότητας των πληροφοριών. Απεικονίζει την κινητοποίηση προγραμμάτων σχετιζόμενων με τη σημαντικότητα επεξεργαζόμενων πληροφοριών. Πρόκειται για την αρνητική κορύφωση του μετρούμενου δυναμικού, η οποία λαμβάνει χώρα από 280 ως 500 msec μετά το ερέθισμα. Συμβάλλει στην εξέταση μηχανισμών που σχετίζονται με τη γλώσσα, το εννοιολογικό και συντακτικό της περιεχόμενο. Αναγνωρίζεται δηλαδή ως ο δείκτης σημαντικότητας των πληροφοριών. Στον τυπικό πειραματικό σχεδιασμό το N400 παράγεται μετά την εμφάνιση σε οθόνη μιας πρότασης η οποία καταλήγει σε λέξη νοηματικά ασύμβατη με το συνολικό πληροφοριακό υλικό.

- P400: θεωρείται ο δείκτης που αντικατοπτρίζει τα συστήματα επεξεργασίας πληροφοριών που σχετίζονται με την συντακτικότητα των πληροφοριών.
- P600: Αντιστοιχεί στη χρονική περίοδο τελικής οργάνωσης, ελέγχου και εκτέλεσης της απόφασης που επιλέγεται, όταν ο οργανισμός εκτίθεται σε εκλυτικό ερέθισμα ή σύμπλοκο ερεθισμάτων που έχουν ψυχολογική σπουδαιότητα

Τα βασικά προκλητά δυναμικά που οφείλονται σε οπτικά ερεθίσματα και καταγράφονται στην ινιακή και πλευρική ινιακή περιοχή [132] είναι το P1 (θετική κορυφή, 80–130 ms), το N1 (αρνητική κορυφή, 130–200 ms) και το P2 (θετική κορυφή, 200–300 ms).

Τα βασικά προκλητά δυναμικά που οφείλονται σε ακουστικά ερεθίσματα και καταγράφονται [132] στην μετωπική και κεντρική περιοχή (εξαιτίας της διασποράς του ηλεκτρικού πεδίου στους εγκεφαλικούς ιστούς) είναι μία μικρή θετική κορυφή, το P50 (50–60 ms), το οποίο ακολουθείται από μία μεγαλύτερη αρνητική μετατόπιση το N1 (100–120 ms) και μία θετική εκτροπή το P2 (150–200 ms).


Στη συγκεκριμένη εργασία όλα τα ερεθίσματα είναι οπτικά. Η καταγραφή των ERPs είναι ένας μη επεμβατικός τρόπος εκτίμησης της εγκεφαλικής λειτουργίας και δραστηριότητας. Η φύση τους είναι τέτοια, ώστε να παρατηρούνται σε συγκεκριμένα και διακριτά χρονικά διαστήματα, τα οποία είναι πολύ μικρής διάρκειας, της τάξης των χιλιοστοδευτερολέπτων (ms).

Επειδή όμως η απόκριση ενός ERP είναι πάρα πολύ μικρή σε χρονική διάρκεια, είναι δύσκολο να την απομονώσουμε από τη συνολική δραστηριότητα του εγκεφάλου [64]. Επίσης το μέγεθός τους είναι της τάξης του 1  $\mu$ V, άρα χρειάζονται ενίσχυση. Για τους λόγους αυτούς αναπτύχθηκε η μέθοδος υπολογισμού του μέσου όρου (EP averaging) πολλών επαναλήψεων του ίδιου πειράματος, η οποία βοηθά να ξεχωρίσουμε ένα μικρό σήμα από ένα μεγάλο

σύνολο θορύβων. Με αυτόν τον τρόπο μια απόκλιση λόγω οποιουδήποτε εκτός πειράματος ερεθίσματος, θα είναι αμελητέα από τις επιθυμητές μετρήσεις.

Στη συγκεκριμένη εργασία λάβαμε τις κυματομορφές των Προκλητικών Δυναμικών, κάνοντας averaging ως προς τα epochs των 32 καναλιών για κάθε δοκιμασία (task) και για κάθε άτομο (subject) του πειράματός μας.

Στην *Εικόνα 21* φαίνονται τα ERSPs ενός subject κατά τη διαδικασία αναγνώρισης «δύσκολης εικόνας» και αναπαράσταση της κεφαλής στα 94 ms μετά το ερέθισμα (εικόνα από το eeglab).




*Εικόνα 21:* Διάγραμμα ERP των 28 καναλιών

#### **4.3.4 Φασματικές Διαταραχές Σχετιζόμενες με το Γεγονός (Event Related Spectral Perturbation -ERSPs)**

Η ERSP αποτελεί την ανάλυση των ERPs στο πεδίο των συχνοτήτων. Κατά την προσέγγιση αυτή [66] υπολογίζονται οι μέσοι όροι των μεταβολών του φάσματος ισχύος συχνοτήτων (frequency power spectrum) ολόκληρου του EEG σήματος, εντοπισμένου χρονικά σε σταθερά γεγονότα (events). Από τους

υπολογισμούς παράγεται μια εικόνα δύο διαστάσεων την οποία καλούμε Event Related Spectral Perturbation (ERSP).

Στην Εικόνα 22 φαίνεται το ERSP ενός subject κατά τη διαδικασία αναγνώρισης «εύκολης εικόνας» (εικόνα από το eeglab).



**Εικόνα 22:** Υπολογισμός δεικτών ERSP και ITC ενός subject κατά τη διαδικασία αναγνώρισης «εύκολης εικόνας»

#### 4.3.5 Inter Trial Coherence – ITCs

Το Inter Trial Coherence (ITC) αποτελεί την ανάλυση των ERPs στην frequency-domain προσέγγιση. Ο δείκτης αυτός συνεισφέρει στη μελέτη του μηχανισμού της προσοχής και στην εγκεφαλική λειτουργία της απόκτησης γνώσης [128].


Στην Εικόνα 22 φαίνεται το ITC που υπολογίσθηκε για το κανάλι 10 και την εύκολη εκπαιδευτική διαδικασίαν ενός από τα άτομα του πειράματος. Οι υπολογισμοί έγιναν με τις συναρτήσεις του EEGLab.

#### 4.3.6 Φασματική Ισχύς Σήματος - Power Spectral

Το power spectral δείχνει την ισχύ κάθε φασματικής συνιστώσας της κυματομορφής. Είναι δείκτης που χρησιμοποιείται συχνά για την ανάλυση φυσιολογικών σημάτων. Ορίζεται ως το τετράγωνο του μέτρου του φάσματος. Ως παράδειγμα απεικόνισης, στην ακόλουθη εικόνα φαίνεται το Power Spectral,



όπως υπολογίσθηκε για το κανάλι 10 και την εύκολη εκπαιδευτική διαδικασία ενός ατόμου του πειράματος.



**Εικόνα 23:** Υπολογισμός δείκτη Power Spectral κατά τη διαδικασία αναγνώρισης «δύσκολης εικόνας»

#### 4.4 Ανάλυση Διακύμανσης

Στην παρούσα παράγραφο θα παρουσιάσουμε μια μέθοδο την οποία χρησιμοποιήσαμε προκειμένου να εξετάσουμε τη διαφορετικότητα των δεικτών πρόβλεψης δυσκολίας. Η μέθοδος είναι γνωστή ως μέθοδος μικτής ANOVA και η οποία εξετάζει διαφορές στους μέσους όρους διαφόρων πληθυσμών ή ομάδων δεδομένων. Σκοπός της εφαρμογής αυτής της μεθόδου είναι ο διαχωρισμός της επιρροής των διαφορετικών υποσυνόλων των παραμέτρων πάνω στις παρατηρήσεις [164].

Έστω οι πληθυσμοί, όπως περιγράφονται στον Πίνακας 2, όπου  $k$  θα είναι οι ανεξάρτητοι πληθυσμοί δεδομένων, τους οποίους θέλουμε να κατατάξουμε ανάλογα με την «επίδραση» από τις διαφορετικού είδους συνθήκες. Στην παρούσα διδακτορική διατριβή, οι επιδράσεις που αναφέρονται είναι οι διαφορετικής δυσκολίας εκπαιδευτικές διαδικασίες.

| Ομάδες    |          |     | Πλήθος   | Άθροισμα | Μέσος όρος | Διακύμανση  |
|-----------|----------|-----|----------|----------|------------|-------------|
| Στήλη 1   | $Y_{11}$ | ... | $Y_{1N}$ | $N$      | $Y_1$      | $M(Y_{1i})$ |
| Στήλη 2   | $Y_{21}$ | ... | $Y_{2N}$ | $N$      | $Y_2$      | $M(Y_{2i})$ |
| Στήλη 3   | $Y_{31}$ | ... | $Y_{3N}$ | $N$      | $Y_3$      | $M(Y_{3i})$ |
| Στήλη $k$ | $Y_{k1}$ | ... | $Y_{kN}$ | $N$      | $Y_k$      | $M(Y_{ki})$ |

Πίνακας 2 : Πίνακας Διαχείρισης Μεταχείρισης

όπου

$$Y_i = \sum_{j=1}^{n_i} Y_{ij} \quad Y_{..} = \sum_{i=1}^k Y_i$$

$$\bar{Y}_i = Y_i / n_i \quad \bar{Y}_{..} = Y_{..} / N$$

και

$$Y_{ij} = \mu_i + \varepsilon_{ij}$$

Το  $\varepsilon_{ij}$  μετρά την απόκλιση της  $j$ -παρατήρησης στο  $i$ -δείγμα από τον αντίστοιχο μέσο  $\mu_i$  της  $i$ -επίδρασης. (Δηλαδή το  $\varepsilon_{ij}$  είναι το τυχαίο λάθος).

Αν

$$\bar{i} = (1/k) \sum_i i$$

τότε

$\mu_i = \mu + \alpha_i$ , όπου  $\alpha_i$  είναι ένας όρος που εκφράζει το αποτέλεσμα (effect) της  $i$  επίδρασης.

Δηλαδή, τελικά

$$Y_{ij} = \mu + \alpha_i + \varepsilon_{ij} \quad \sum_{i=1}^k \alpha_i = 0 \quad \varepsilon_{ij} \sim N(0, \sigma^2).$$

Η συνολική απόκλιση μετριέται από το άθροισμα

$$\begin{aligned} \sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y}_{..})^2 &= \sum_i \sum_j [(Y_{ij} - \bar{Y}_i) + (\bar{Y}_i - \bar{Y}_{..})]^2 \\ &= \sum_i \sum_j (Y_{ij} - \bar{Y}_i)^2 + 2 \sum_i \sum_j (Y_{ij} - \bar{Y}_i)(\bar{Y}_i - \bar{Y}_{..}) + \sum_i \sum_j (\bar{Y}_i - \bar{Y}_{..})^2 \end{aligned}$$

Αυτό μπορεί να αποδειχθεί ότι αναλύεται σε δύο προσθετικές συνιστώσες, ως εξής:

$$\sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y}_{..})^2 = \sum_i n_i (\bar{Y}_i - \bar{Y}_{..})^2 + \sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y}_i)^2$$

Με

$$\sum_i \sum_j (\bar{Y}_i - \bar{Y}_{..})^2 = \sum_i n_i (\bar{Y}_i - \bar{Y}_{..})^2 = \frac{\sum_i Y_i^2}{n_i} - \frac{(\bar{Y}_{..})^2}{N}$$

Αν συμβολίσουμε με

$$SST (\equiv \Sigma AT) = \sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y}_{..})^2$$

Τη συνολική τετραγωνική απόκλιση, με

$$SST_r (\equiv \Pi AT) = \sum_i \sum_j (\bar{Y}_i - \bar{Y}_{..})^2$$

Τη συνολική τετραγωνική απόκλιση που οφείλεται στις επιδράσεις (treatments) και με

$$SSE (\equiv \Lambda AT) = \sum_i \sum_j (Y_{ij} - \bar{Y}_i)^2$$

Την τετραγωνική απόκλιση του λάθους, θα έχουμε :

$$SST = SSTr + SSE.$$

Η συνολική διακύμανση δηλαδή, αναλύθηκε σε δύο προσθετικές συνιστώσες. Σε αυτήν που μπορεί να αποδοθεί σε διαφορές "μεταξύ" των επιδράσεων (between treatments) και σε εκείνη που αποδίδεται σε διάφορες "μέσα" σε κάθε επίδραση ("within" treatments), δηλαδή τα τυχαία λάθη.

Η μέθοδος της ανάλυσης διασποράς στηρίζεται στο να βρει κανείς αν οι παρατηρηθείσες διαφορές ανάμεσα στους μέσους των διαφορών "επιδράσεων" οφείλονται σε τυχαίους λόγους ή σε συστηματική διαφορά ανάμεσα στις διαφορετικές επιδράσεις.

Αποδεικνύεται ότι :

$$E\left(\frac{SSTr}{k-1}\right) = \sigma^2 + \frac{\sum_i n_i \alpha_i^2}{k-1}$$

Και επομένως κάτω από την  $H_0$

$$E\left(\frac{SSTr}{k-1}\right) = \sigma^2$$

θέτοντας

$$s_0^2 = \frac{SSTr}{k-1}$$

έχουμε

$$E(s_0^2) = \sigma^2$$

Από το άλλο μέρος κάθε ένα από τα  $k$  δείγματα δίνουν μία εκτίμηση του  $\sigma^2$

$$s_i^2 = \frac{1}{n_i - 1} \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y}_i)^2$$

Αν θεωρήσουμε τη σταθμισμένη "εκτιμήτρια"  $Sp^2$  (pooled variance), το  $\sigma^2$  από τα  $k$  δείγματα θα έχουμε:

$$\begin{aligned}
 S_p^2 &= \frac{(n_1 - 1)S_1'^2 + (n_2 - 1)S_2'^2 + \dots + (n_k - 1)S_k'^2}{N - k} \\
 &= \frac{\sum_{i=1}^k (n_i - 1)S_i'^2}{N - k} \\
 &= \frac{\sum_{i=1}^k \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y}_i)^2}{N - k} \\
 &= \frac{SSE}{N - k}
 \end{aligned}$$

(ανεξάρτητα από το αν ισχύει η  $H_0$  ή  $H_1$  ).

Τότε, αν η  $H_0$  είναι σωστή, έχουμε ότι:

$$F = \frac{S_0^2}{S_p^2} \sim F_{k-1, N-k}$$

Όταν η  $H_0$  δεν είναι σωστή, θα πρέπει ο παράγοντας SSTr να είναι μεγάλος (δηλαδή το  $S_0^2$  να είναι μεγάλο σε σχέση με το  $S_p^2$  ).

Τότε, απορρίπτουμε την  $H_0$ , αν

$$F > F_{k-1, N-k, 1-\alpha}$$

Τα παραπάνω αποτυπώνονται στον πίνακα που ακολουθεί. Ο πίνακας αυτός ονομάζεται πίνακας ανάλυσης διακύμανσης (διασποράς) (Analysis of Variance ή ANOVA table).

| ΑΝΑΛΥΣΗ ΔΙΑΚΥΜΑΝΣΗΣ                            |                              |                            |                                   |                                        |
|------------------------------------------------|------------------------------|----------------------------|-----------------------------------|----------------------------------------|
| Προέλευση<br>διακύμανσης                       | Άθροισμα<br>Τετραγώνων<br>SS | βαθμοί<br>ελευθερίας<br>DF | Μέσα<br>Τετραγωνικά<br>Λάθη<br>MS | F<br>κάτω<br>από την<br>H <sub>0</sub> |
| Μεταξύ<br>Επιδράσεων<br>(between treatments)   | SSTr                         | k-1                        | $S_0^2 = \frac{SSTr}{k-1}$        | $F = \frac{S_0^2}{S_p^2}$              |
| Μέσα στις<br>Επιδράσεις<br>(within treatments) | SSE                          | N-k                        | $S_p^2 = \frac{SSE}{N-k}$         |                                        |
| Σύνολο                                         | SST                          | N-1                        |                                   |                                        |

Πίνακας 3 : Πίνακας Ανάλυσης Διακύμανσης Διασποράς ANOVA

Συνήθως χρησιμοποιούμε τους ισοδύναμους τύπους :

$$\begin{aligned} SST &= \sum_{i=1}^k \sum_{j=1}^{n_i} Y_{ij}^2 - \frac{Y_{..}^2}{N} \\ SST_r &= \sum_{i=1}^k \frac{Y_{i.}^2}{n_i} - \frac{Y_{..}^2}{N} \\ SSE &= \sum_i \sum_j Y_{ij}^2 - \sum_i \frac{Y_{i.}^2}{n_i} \end{aligned}$$

Οι υπολογισμοί της ανάλυσης διακύμανσης της παραγράφου 6.3.7 έγιναν με τη βοήθεια του στατιστικού πακέτου SPSS[160].

Στην παράγραφο 6.3.7 χρησιμοποιούμε την ανάλυση διακύμανσης με τη μέθοδο της μικτής ANOVA, για να προσδιορίσουμε, εάν οποιαδήποτε αλλαγή στη δυσκολία μάθησης (δηλαδή, η εξαρτημένη μεταβλητή) είναι το αποτέλεσμα της αλληλεπίδρασης μεταξύ του τύπου της αγωγής (δηλαδή, το πρόγραμμα εκπαίδευσης Α ή το πρόγραμμα εκπαίδευσης Β). Με την ανάλυση αυτή θα ανακαλύψουμε, εάν η διαφοροποίηση μεταξύ των δεδομένων των δύο μεθόδων μάθησης μπορούν να δώσουν διαφοροποίηση στη δυσκολία μάθησης.

## 5. ΣΥΝΘΗΚΕΣ & ΕΡΓΑΛΕΙΑ

### 5.1 Περιγραφή Συνθηκών Πειράματος και Δεδομένα

Τα δεδομένα που χρησιμοποιήθηκαν, διανέμονται από τους ερευνητές κάτω από την άδεια GNU/GPL και πιο συγκεκριμένα στη διεύθυνση :

[http://sccn.ucsd.edu/~arno/fam2data/publicly\\_available\\_EEG\\_data.html](http://sccn.ucsd.edu/~arno/fam2data/publicly_available_EEG_data.html)

#### Πειραματική Διαδικασία

Οι συμμετέχοντες κάθονται σε ένα αμυδρά φωτισμένο δωμάτιο σε απόσταση 110 cm από την οθόνη ενός υπολογιστή. Υπάρχουν δύο εργασίες οι οποίες εναλλάσσονται. Η μια είναι εργασία κατηγοριοποίησης, ενώ η άλλη είναι μια εργασία αναγνώρισης. Σε αμφοτέρες τις εργασίες, τόσο οι εικόνες στόχοι, όσο και οι εικόνες μη στόχοι είχαν ίσες πιθανότητες εμφάνισης. Οι συμμετέχοντες εξετάστηκαν σε δύο φάσεις. Την πρώτη μέρα έγιναν 13 σειρές καταγραφής, ενώ τη δεύτερη ημέρα έγιναν 12 σειρές καταγραφής με 100 εικόνες ανά σειρά. Για να ξεκινήσει μια σειρά, τα άτομα έπρεπε να πατήσουν ένα κουμπί αφής. Ένα μικρό σημείο (μικρότερο από  $0,1^\circ$  του οπτική γωνία ίση) υπήρχε στη μέση της μαύρης οθόνης. Στη συνέχεια, μια 8 bit χρώματος κάθετη φωτογραφία (256 pixels πλάτος και 384 pixels ύψος, που αντιστοιχεί περίπου σε  $4,5^\circ$  οπτικής γωνίας σε πλάτος και  $6,5^\circ$  σε ύψος) εμφανίστηκε για 20 ms (2 καρέ από μια οθόνη SVGA 100 Hz), χρησιμοποιώντας ένα προγραμματιζόμενο graphic board (VSG 2.1, Cambridge Research Systems). Αυτή η σύντομη παρουσίαση γίνεται, για να αποφευχθεί από τα άτομα που συμμετέχουν να χρησιμοποιήσουν διερευνητική κίνηση ματιών, για να απαντήσουν. Οι συμμετέχοντες έδωσαν τις απαντήσεις τους με ένα παράδειγμα go / nogo. Για κάθε στόχο έπρεπε να ανασηκώσουν το δάχτυλό τους από το κουμπί όσο πιο γρήγορα και όσο το δυνατόν ακριβέστερα (απελευθερώνοντας το κουμπί εμφανίζεται μια εστιασμένη δέσμη φωτός ανάμεσα σε μια optic fiber led και του δέκτη του. Η λανθάνουσα απόκριση αυτής της συσκευής ήταν κάτω από 1 ms). Στους συμμετέχοντες δόθηκαν 1000 ms, προκειμένου να ανταποκριθούν, έτσι ώστε η απάντηση να ήταν go, αλλιώς μετά από το διάστημα αυτό η απάντηση θεωρήθηκε ως απάντηση nogo. Το ερέθισμα έναρξης ήταν ασύγχρονο (stimulus onset asynchrony - SOA). Πιο συγκεκριμένα,


ήταν 2000 ms συν ή πλην μια τυχαία καθυστέρηση των 200 ms. Για κάθε distractor, οι συμμετέχοντες έπρεπε να κρατήσουν το πάτημα του κουμπιού κατά τη διάρκεια τουλάχιστον 1000 ms (απόκριση nogo).

Πιο συγκεκριμένα, στην εργασία όπου υπήρχε κατηγοριοποίηση ζώων, οι συμμετέχοντες έπρεπε να απαντήσουν όποτε υπήρχε ένα ζώο στην εικόνα. Στο έργο αναγνώρισης η συνεδρία ξεκινούσε με μια φάση εκμάθησης. Οι συμμετέχοντες έλαβαν οδηγίες να εξετάσουν προσεκτικά και να μάθουν μια εικόνα (ενός ζώου), ώστε να την αναγνωρίσουν στη σειρά που θα ακολουθούσε. Η κανονική φάση ξεκινούσε αμέσως μετά τη φάση της εκμάθησης. Η εικόνα προς ανίχνευση αποτελούσε τον μοναδικό στόχο αυτής της σειράς. Και οι δύο εργασίες οργανώθηκαν σε μια σειρά των 100 εικόνων, 50 εικόνες στόχοι αναμίχθηκαν με 50 εικόνες μη στόχοι στην εργασία κατηγοριοποίησης. Επίσης 50 φωτογραφίες που περιείχαν μια φωτογραφία ζώου (φωτογραφίες στόχοι) αναμίχθηκαν με τυχαία σειρά με 50 φωτογραφίες που δεν είχαν το ζώο (φωτογραφίες μη στόχοι) στην εργασία της αναγνώρισης, *Εικόνα 24*, *Εικόνα 25*, *Εικόνα 26*.

### **Το ερέθισμα**

Οι εικόνες ήταν φωτογραφίες φυσικών σκηνών (Corel CD-ROM library, εικόνες οι οποίες είναι διαθέσιμες για προβολή από την download page - <http://sccn.ucsd.edu/~arno/fam2data/anima4b/>). Οι εικόνες της κάθε κατηγορίας επιλέχθηκαν, ώστε να ποικίλλουν όσο το δυνατόν περισσότερο. Η κατηγορία των ζώων περιλάμβανε φωτογραφίες από θηλαστικά, πουλιά, ψάρια, αρθρόποδα, και ερπετά. Δεν υπήρχε καμιά a priori πληροφορία σχετικά με το μέγεθος, τη θέση ή τον αριθμό των στόχων σε μια φωτογραφία. Υπήρχε, επίσης, ένα ευρύ φάσμα non-target εικόνων, με εξωτερικές και εσωτερικές σκηνές, φυσικά τοπία ή σκηνές της πόλης, εικόνες τροφίμων, φρούτων, λαχανικών, δέντρων και λουλουδιών ...






Εικόνα 24: Μια non-target εικόνα



Εικόνα 25: Μια target easy (εύκολη) εικόνα



Εικόνα 26: Μια target hard (δύσκολη) εικόνα

A) Στην εργασία της κατηγοριοποίησης, 500 distractors (παραπλανητικές εικόνες) και 500 targets (εικόνες στόχοι) χρησιμοποιήθηκαν από όλα τα θέματα και τυχαία κατανεμήθηκαν ανάμεσα στις 10 σειρές.

B) Στην εργασία αναγνώρισης, χρησιμοποιήθηκαν 750 non target και 210 target φωτογραφίες (15 target φωτογραφίες ανά άτομο - 14 άτομα). Οι target φωτογραφίες επιλέχθηκαν σύμφωνα με τα αποτελέσματα μιας προηγούμενης έρευνας (Fabre-Thorpe et al., 2001). Η πρώτη ομάδα των 70 εικόνων (5 ανά άτομο - 14 άτομα) συστάθηκε από 1000 εικόνες ζώων οι οποίες ορθώς κατηγοριοποιήθηκαν από όλα τα άτομα και συσχετίστηκαν με τις ταχύτερες τιμές RTs (Reaction Time - easy images). Η δεύτερη ομάδα των 70 εικόνων αποτελούνταν από φωτογραφίες ζώων, που είχαν τη χαμηλότερη ακρίβεια και συνδέονται με τις μεγαλύτερες τιμές RTs (hard images). Σε κάθε task αναγνώρισης εμφανίσθηκαν 100 trials (100 εικόνες). Κάθε 100άδα περιείχε 50 target εικόνες και 50 non-target (distractors).

### Συνθήκες πειράματος

Από τις δύο ειδών εργασίες που περιγράφηκαν πιο πάνω, στη συγκεκριμένη διδακτορική διατριβή χρησιμοποιήθηκαν οι εργασίες αναγνώρισης.

Υπήρξαν 14 subjects, 25 trials για κάθε subject. Από αυτά τα 10 trials (5 και 5) αφορούν hard and easy images. Έχουμε 100 images για κάθε trial και για κάθε trial έχουμε περίπου 100.000 points (200.000 ms) και κάθε εικόνα εμφανίζεται για περίπου 1000 points (2000 ms) (1 point 2ms άρα 1000 points 2000 ms).




Figure 3 Experiment Procedure

**Εικόνα 27:** Σχηματική αναπαράσταση της ερευνητικής διαδικασίας

Η περιγραφή της πειραματικής διαδικασίας για μια απάντηση, φαίνεται στην Εικόνα 28



**Εικόνα 28:** Περιγραφή πειραματικής διαδικασίας για μια απάντηση

## 5.2 Χωρική Διάταξη Ηλεκτροδίων

Ηλεκτροεγκεφαλογραφικά δυναμικά καταγράφηκαν από 32 ηλεκτρόδια τα οποία ήταν προσδεμένα επάνω σε ένα ελαστικό καπέλο (Oxford Instruments).



**Εικόνα 29:** Ελαστικό καπέλο με τα 32 ηλεκτρόδια  
(public domain image, free to use, share or modify, even commercially)


Το ηλεκτρόδιο Cz χρησιμοποιήθηκε ως αναφορά και ένα μαστοειδές ηλεκτρόδιο (mastoid electrode) χρησιμοποιήθηκε για γείωση.



**Εικόνα 30:** Τοπολογία ηλεκτροδίων με το μαστοειδές ως αναφορά  
(public domain image, free to use, share or modify, even commercially)

Η λήψη των δεδομένων πραγματοποιήθηκε στα 1000 Hz (που αντιστοιχεί σε ένα point ανά 1 ms) χρησιμοποιώντας ένα σύστημα καταγραφής SynAmps σε συνδυασμό με έναν υπολογιστή PC. Οι αντιστάσεις κρατήθηκαν κάτω από 5 kOhms.

Η χωρική διάταξη των ηλεκτροδίων που χρησιμοποιήθηκε ήταν η εξής :



**Εικόνα 31:** Η Χωρική Διάταξη των 32 Ηλεκτροδίων [147]

Επίσης, στην *Εικόνα 32*, φαίνεται η ονοματοδοσία των ηλεκτροδίων και η αντιστοίχιση ονομάτων και ηλεκτροδίων (καναλιών). Για παράδειγμα, στο 29 ηλεκτρόδιο αντιστοιχεί η φωτοδίοδος, η οποία καταγράφει τα events.

Το αρχείο loc με τις ακριβείς θέσεις των ηλεκτροδίων στο τριχωτό της κεφαλής, φαίνεται στην

|    |      |            |      |
|----|------|------------|------|
| 1  | -18  | 0.34074074 | FP1. |
| 2  | 18   | 0.34074074 | FP2. |
| 3  | -39  | 0.22222222 | F3.. |
| 4  | 39   | 0.22222222 | F4.. |
| 5  | -90  | 0.17037037 | C3.. |
| 6  | 90   | 0.17037037 | C4.. |
| 7  | -141 | 0.22222222 | P3.. |
| 8  | 141  | 0.22222222 | P4.. |
| 9  | -162 | 0.34074074 | O1.. |
| 10 | 162  | 0.34074074 | O2.. |
| 11 | -54  | 0.34074074 | F7.. |
| 12 | 54   | 0.34074074 | F8.. |
| 13 | -90  | 0.34074074 | T3.. |
| 14 | 90   | 0.34074074 | T4.. |
| 15 | -126 | 0.34074074 | T5.. |
| 16 | 126  | 0.34074074 | T6.. |
| 17 | 0    | 0.17037037 | FZ.. |
| 18 | 180  | 0.17037037 | PZ.. |
| 19 | -108 | 0.34074074 | T5'. |
| 20 | 108  | 0.34074074 | T6'. |
| 21 | -144 | 0.34074074 | O1'. |
| 22 | 144  | 0.34074074 | O2'. |
| 23 | -151 | 0.27407407 | P3". |
| 24 | 151  | 0.27407407 | P4". |
| 25 | 180  | 0.25555556 | PZ". |
| 26 | 180  | 0.34074074 | OZ.. |
| 27 | 180  | 0.42592593 | I... |
| 28 | -162 | 0.42592593 | CB1" |
| 29 | 162  | 0.42592593 | CB2" |
| 30 | -144 | 0.42592593 | CB1. |
| 31 | 144  | 0.42592593 | CB2. |


**Εικόνα 32:** Αρχείο loc με τις ακριβείς θέσεις και ονομασίες των ηλεκτροδίων

### 5.3 Το περιβάλλον EEGLab

Για την επεξεργασία των δεδομένων χρησιμοποιήθηκε το λογισμικό EEGLab [152]. Ένα λογισμικό το οποίο αποτελεί πρόσθετο του Matlab. Το λογισμικό EEGLab αναπτύχθηκε στο Swartz Center for Computational Neuroscience [152],



και είναι matlab structure. Χρησιμοποιείται στην ανάλυση δεδομένων EEG (Ηλεκτροεγκεφαλογραφημάτων) και MEG (Μαγνητοεγκεφαλογραφημάτων). Έχει πάρα πολλές δυνατότητες, όπως η παρουσίαση και η επεξεργασία όλου του σήματος απ' όλα τα ηλεκτρόδια, φιλτράρισμα, παραγωγή ανεξάρτητων συνιστωσών, καθάρισμα από ανεπιθύμητα παράσιτα (π.χ. οφθαλμικά), παραγωγή διαγραμμάτων ERPs, ERSPs, ITCs,, φασματική ανάλυση και πολλά άλλα.



**Εικόνα 33:** Λογισμικό EEGLab

Στη συγκεκριμένη εργασία χρησιμοποιήθηκε για την ανάλυση των σημάτων και την εξαγωγή όλων των διανυσμάτων δεικτών και διαγραμμάτων. Επίσης χρησιμοποιήθηκε για τη διαδικασία epoching των δεδομένων.

Στο (<http://sccn.ucsd.edu/wiki/Eeglab>) υπάρχει μεγάλο, εκτενές εγχειρίδιο χρήσης με παραδείγματα. Επίσης υπάρχει σελίδα wiki [154] καθώς και ετήσια workshops (το τελευταίο στο [150]) με πολύ χρήσιμες δημοσιεύσεις, για αυτούς που χρησιμοποιούν το toolbox.

Σε κάποια πειράματα για την προ-επεξεργασία των ακατέργαστων σημάτων EEG. Χρησιμοποιήθηκαν τα φίλτρα που προτείνει το EEGLAB (short IIR filter).

Πρώτα εφαρμόζεται υψιπερατό φίλτρο στα 0.5 Hz, ακολουθεί ένα φίλτρο τύπου notch στα 50 Hz για τον καθαρισμό του θορύβου της ηλεκτρικής γραμμής. Τέλος, εφαρμόζεται χαμηλοπερατό φίλτρο στα 90 Hz.

Επίσης σε κάποια σήματα τα οποία κρίθηκε ότι περιείχαν αρκετό θόρυβο, εφαρμόστηκε ICA (Independent Component Analysis), για την εξαγωγή ανεξάρτητων συνιστωσών και αποθορυβοποίηση του σήματος από μυϊκά, οφθαλμολογικά ή άλλου τύπου παράσιτα (artifactual rejection).

Το EEGLab υποστηρίζει ένα πολύ μεγάλο αριθμό σχημάτων (format) δεδομένων και αυτό είναι ένας λόγος που το καθιστά τόσο ισχυρό.

Περιλαμβάνει διαδικασίες ploating, απεικόνισης στο κεφάλι και υποστηρίζει όλες τις γνωστές συνδεσμολογίες των ηλεκτροδίων στο ηλεκτροεγκεφαλογράφημα.


#### **5.4 Διαδικασία εξαγωγής εποχών**

Για να είναι δυνατή η επεξεργασία των σημάτων, έγινε εξαγωγή εποχών. Για τη διαδικασία αυτή χρησιμοποιήθηκε αρχείο δεδομένων, το οποίο διατίθεται επίσης από τους ερευνητές που μας διέθεσαν τα δεδομένα [171]. Το αρχείο που συνοδεύει τα δεδομένα, δίνει τις ακριβείς στιγμές που συμβαίνουν τα events και τη χρονική διάρκεια κάθε εποχής (ας μην ξεχνάμε ότι η διάρκεια των εποχών δεν είναι σταθερή αλλά έχει μια διάρκεια  $\pm 200$  ms). Με αυτόν τον τρόπο έγινε συγχρονισμός των νευροφυσιολογικών δεδομένων με τα οπτικά ερεθίσματα.

Η εμφάνιση κάθε εικόνας αντιστοιχεί σε ένα event, ενώ ως εποχή ορίζεται ένα κομμάτι σήματος γύρω από το event. Αυτό το κομμάτι καθορίζεται από κάποιο χρόνο πριν από την εμφάνιση του γεγονότος και κάποιο χρόνο μετά την εμφάνιση του γεγονότος. Κάθε ένα από τα σήματα είχε περίπου 100 εποχές, με κάθε εποχή να περιέχει 1000 σημεία (1ms ανά σημείο).



Η χρονική περίοδος πριν το ερέθισμα ονομάζεται pre-stimulus, ενώ το χρονικό διάστημα μετά το ερέθισμα ονομάζεται post-stimulus. Το ερέθισμα εμφανίζεται σε κάθε εποχή περίπου 100 ms μετά την εκκίνηση της εποχής και στα διαγράμματα που θα δούμε στο 5<sup>ο</sup> κεφάλαιο, όπου παρουσιάζονται τα αποτελέσματα, η εκκίνηση κάθε εποχής εμφανίζεται ως -100ms, στο 0 εμφανίζεται το ερέθισμα, ενώ το τέλος της εποχής καταγράφεται στα 900 περίπου ms μετά το ερέθισμα.



**Εικόνα 34:** Περιγραφή χρονικού διαστήματος pre και post stimulus

### 5.5 Ταξινομητές – Το περιβάλλον WEKA

Το περιβάλλον που χρησιμοποιήσαμε για την αξιολόγηση των διανυσμάτων των δεικτών και για την τελική εξόρυξη γνώσης ήταν το λογισμικό WEKA. Στην παρούσα παράγραφο αναφέρουμε κάποια στοιχεία για το λογισμικό αυτό.

Μετά τη σχετική προεπεξεργασία των δεδομένων που ήδη περιγράψαμε, εφαρμόζουμε κατάλληλους αλγόριθμους από το EEGLab, προκειμένου να εξάγουμε τους διανυσματικούς δείκτες. Αφού εξαχθούν λοιπόν τα επιθυμητά διανύσματα δεικτών, αυτό που πρέπει να πράξουμε στη συνέχεια είναι να τα αξιολογήσουμε και να εξάγουμε την πληροφορία για το καλύτερο μοντέλο πρόβλεψης της δυσκολίας της εκπαιδευτικής διαδικασίας. Για να μπορέσει να πραγματοποιηθεί αυτό, χρησιμοποιήθηκαν μια σωρεία αλγόριθμων ταξινόμησης. Ο ταξινομητής είναι ένας αλγόριθμος, ο οποίος λαμβάνει δεδομένα χωρισμένα σε κλάσεις, εκπαιδεύεται, ώστε να καταλάβει τη σχέση μεταξύ κάποιων χαρακτηριστικών και των κλάσεων που θα αντιστοιχίζονται στην ουσία στις πράξεις και κατ'επέκταση στη δυσκολία τους και στη συνέχεια είναι δυνατόν, λαμβάνοντας κάποιες τιμές, να προβλέπει σε ποια κλάση μπορούν

αυτές να κατηγοριοποιηθούν. Στην ουσία δηλαδή, μπορεί να προβλέπει τελικά στην περίπτωση μας ποια είναι η δυσκολία που αντιμετωπίζει το υποκείμενο (subject), δίνοντάς του μια τιμή από κάποιο χαρακτηριστικό.



Εικόνα 35: Η πρώτη οθόνη του λογισμικού WEKA

Στο Παράρτημα Α υπάρχει εκτενέστερη αναφορά στο περιβάλλον WEKA

### 5.5.1 Η μορφή των δεδομένων ARFF

Η μορφή των δεδομένων που φορτώνονται στο περιβάλλον WEKA έχουν συγκεκριμένη μορφή και σχήμα. Η επέκτασή τους είναι .arff και η δομή τους περιγράφεται στη συνέχεια. Υπάρχει η δυνατότητα, μέσω των επιλογών του συστήματος Weka, να μετατρέψουμε τα αρχεία από excel σε arff. Τα δεδομένα έχουν τη μορφή <πρότυπο x>:<κατηγορία y>. Όπως θα δούμε με λεπτομέρεια και στη συνέχεια, ένα κομμάτι των δεδομένων χρησιμοποιείται σαν σύνολο εκπαίδευσης (training set), ενώ τα υπόλοιπα παίρνουν μέρος στη φάση ελέγχου του συστήματος που γίνεται στο τέλος της φάσης εκπαίδευσης. Κάποια από τα δεδομένα εκπαίδευσης αποτελούν το σύνολο επικύρωσης (validation set) για την οργάνωση του συστήματος. Μία άλλη βάση γνώσης μπορεί να εισαχθεί για τη φάση κανονικής λειτουργίας.

Ένα αρχείο arff έχει την ακόλουθη δομή [145] :

@relation <όνομα προβλήματος>

@attribute <όνομα χαρακτηριστικού 1> <εύρος τιμών χαρακτηριστικού 1>

```
@attribute < όνομα χαρακτηριστικού 2> < εύρος τιμών χαρακτηριστικού 2>
.
.
@attribute < όνομα χαρακτηριστικού ν> < εύρος τιμών χαρακτηριστικού ν>
@attribute <όνομα τάξης> <πιθανές επιγραφές τάξεων>

@data
<τιμή χαρακτηριστικού 1>,< τιμή χαρακτηριστικού 2> ,..., < τιμή χαρακτηριστικού ν>,<τάξη προτύπου 1>
< τιμή χαρακτηριστικού 1>,< τιμή χαρακτηριστικού 2> ,..., < τιμή χαρακτηριστικού ν>,< τάξη προτύπου 2>
.
.
< τιμή χαρακτηριστικού 1>,< τιμή χαρακτηριστικού 2> ,..., < τιμή χαρακτηριστικού ν>,< τάξη προτύπου μ>
```

Μέσα στα brackets <> τοποθετούμε μεταβλητές, οι οποίες στο αρχείο των δεδομένων αντικαθίστανται από τιμές. Τα χαρακτηριστικά (ή attributes, όπως συναντώνται στη διεθνή βιβλιογραφία) είναι τα στοιχεία του διανυσματικού χώρου εισόδου συν ένα για την τάξη του προτύπου. Στην ουσία δηλαδή είναι οι τιμές του διανυσματικού δείκτη, τον οποίο θέλουμε να ταξινομήσουμε. Το εύρος τιμών των attributes μπορεί να είναι συνεχές, οπότε ο αντίστοιχος χαρακτηρισμός είναι REAL, ή να είναι διακριτό, οπότε τοποθετούνται οι πιθανές τιμές μέσα σε αγκύλες π.χ. {0,1}. Το εύρος τιμών του τελευταίου attribute που αντιστοιχεί στην επιγραφή της τάξης πρέπει να είναι πάντα διακριτό και αντιστοιχεί σε μια κωδικοποίηση των κατηγοριών του προβλήματος, π.χ. {0,1} ή {FALSE, TRUE} κ.τ.λ.. Οι τιμές των attributes κάτω από το @data (περιοχή δεδομένων) χωρίζονται με κόμμα (,) ενώ τα διάφορα πρότυπα χωρίζονται με αλλαγή γραμμής. Το σημείο υποδιαστολής για attributes με συνεχείς τιμές είναι η τελεία (.). Παρακάτω παρουσιάζεται ένα παράδειγμα αρχείου που χρησιμοποιήσαμε στα πειράματά μας :

```
@relation Easy_Hard_1_CHANNEL_ERPs

@attribute ERP_Trial_1_CHANNEL REAL
@attribute ERP_Trial_2_CHANNEL REAL
.....
@attribute ERP_Trial_27_CHANNEL REAL
@attribute ERP_Trial_28_CHANNEL REAL

@ATTRIBUTE class {Easy_GFPs_1_SUBJECT, Hard_GFPs_1_SUBJECT}

@data

35.518,38.576,37.253,38.7,27.23,23.311,19.153,18.399,15.753,16.542,30.864,43.811,22.136,27.639,13.434,18.2
67,37.95,33.172,24.156,14.892,37.972,37.291,24.093,35.448,33.147,22.546,25.653,26.565,Easy_GFPs_1_SUBJEC
T
36.544,38.719,39.415,39.707,28.743,22.841,18.811,17.832,14.74,16.4,31.282,43.663,23.824,27.518,12.778,18.4
95,38.873,33.21,23.901,14.837,38.936,38.306,23.89,36.546,33.616,22.727,24.924,26.684,Easy_GFPs_1_SUBJECT
37.158,38.836,40.438,39.784,28.793,22.354,18.181,17.016,13.683,15.812,32.785,43.888,25.047,26.865,12.241,1
7.921,39.507,32.646,23.313,14.572,39.502,38.989,23.386,36.739,33.508,22.414,23.824,27.718,Easy_GFPs_1_SU
```

BJECT

.....


38.423,40.71,24.071,28.601,18.222,19.563,18.873,16.058,14.271,14.062,35.797,41.822,17.477,23.342,13.311,14  
.801,29.335,25.829,22.443,10.646,30.539,26.175,20.105,22.017,22.766,19.35,17.761,19.235,Hard\_GFPs\_1\_SUBJ  
ECT

38.491,39.934,24.781,28.802,18.667,19.763,19.22,15.892,13.808,13.738,35.165,40.678,17.785,22.203,13.324,15  
.363,29.546,25.804,22.327,11.252,30.444,26.401,20.259,22.215,22.701,19.545,17.975,19.489,Hard\_GFPs\_1\_SUB  
JECT


.....

Υπάρχουν δύο κλάσεις Easy, Hard και 28 attributes, τα οποία στην ουσία είναι  
τα 28 κανάλια.

Φορτώνοντας τα αρχεία στην καρτέλα Preprocess, οι εικόνες που βλέπουμε  
είναι αυτές των εικόνων **Εικόνα 36** και **Εικόνα 37**.



Εικόνα 36: Κύρια διεπαφή του Weka Explorer, με τα δεδομένα καταχωρισμένα με βάση 3 κλάσεις




Εικόνα 37: Κάνοντας την επιλογή “Visualize all”

### 5.5.2 Ταξινόμηση (Classification)

Από τη στιγμή που τα δεδομένα έχουν το σωστό σχήμα (format - .arff), στη συνέχεια μεταφερόμαστε στην καρτέλα Classify, από την οποία κάνουμε όλες τις ταξινομήσεις και παίρνουμε τα αντίστοιχα αποτελέσματα. Έχουμε τη δυνατότητα να επιλέξουμε την ταξινόμηση μέσα από πολλούς διαφορετικούς αλγορίθμους. Υπάρχουν και άλλοι πολλοί τρόποι να γίνουν διαδικασίες και έλεγχοι, όπως για παράδειγμα να γίνει ομαδοποίηση (clustering) πρώτα, έτσι ώστε να προκύψουν ομοειδή δεδομένα, αλλά δε θα επεκταθούμε περαιτέρω, αφού όλα αυτά που περιγράψαμε ήταν αρκετά, για να προχωρήσουμε στα δικά μας πειράματα.

Στις επόμενες παραγράφους θα δούμε κάποιους από τους αλγόριθμους που περιλαμβάνονται στο πακέτο WEKA και τους οποίους χρησιμοποιήσαμε στη συγκεκριμένη εργασία.

Στην παρακάτω Εικόνα 38 βλέπουμε μια εικόνα ταξινόμησης.



Εικόνα 38: Αποτέλεσμα Ταξινόμησης

### 5.5.3 Αλγόριθμοι Ταξινόμησης που χρησιμοποιήσαμε

Οι αλγόριθμοι ταξινόμησης (ή ταξινομητές, όπως αποκαλούνται) που χρησιμοποιήσαμε είναι :

| Αλγόριθμοι            |
|-----------------------|
| BayesNet              |
| JRip                  |
| NaiveBayesMultinomial |
| NaiveBayesSimple      |
| DecisionTable         |
| Part                  |
| Ridor                 |
| SMO                   |
| VFI                   |
| ZeroR                 |
| BFTree                |

Πίνακας 4 : Οι Αλγόριθμοι Ταξινόμησης που χρησιμοποιήθηκαν

Αναλυτικά στοιχεία για κάθε ταξινομητή μπορεί κανείς να βρει στο [170] και στο [166], όπου και αναφέρονται για τον καθένα λεπτομέρειες της λειτουργίας του.

Πρέπει να πούμε ότι οι ταξινομητές που διαθέτει το WEKA είναι δεκάδες. Η επιλογή έγινε με βάση την εμπειρία μας και τη βιβλιογραφία. Επίσης έγινε και δοκιμαστική ταξινόμηση με μερικούς ακόμα, πριν καταλήξουμε τελικά στη συγκεκριμένη δεκάδα.

#### **5.5.4 Επεξήγηση των αποτελεσμάτων από το WEKA**

Σ' αυτήν την παράγραφο θα δούμε το αποτέλεσμα μιας ταξινόμησης και θα εξηγήσουμε τα αποτελέσματα. Έστω η εκτέλεση που φαίνεται στην **Εικόνα 38**.

Η έξοδος που δίνει στο παράθυρο classifier output είναι :

=== Run information ===

```
Scheme:weka.classifiers.bayes.BayesNet -D -Q weka.classifiers.bayes.net.search.local.K2 -- -P 1 -S BAYES -E
weka.classifiers.bayes.net.estimate.SimpleEstimator -- -A 0.5
Relation: entropies_Shannon_Norm
Instances: 114
Attributes: 4
    Shannon
    Norm
    Sample
    class
Test mode:10-fold cross-validation
```

[ Τα παραπάνω είναι πληροφορίες για τα δεδομένα τα οποία χρησιμοποιήσαμε. Έχουμε 114 τιμές, με 4 attributes και 2 κλάσεις easy και hard ]

=== Classifier model (full training set) ===

```
Bayes Network Classifier
not using ADTree
#attributes=4 #classindex=3
Network structure (nodes followed by parents)
Shannon(3): class
Norm(3): class
Sample(2): class
class(2):
LogScore Bayes: -322.46000678158805
LogScore BDeu: -335.13774040643483
LogScore MDL: -339.0837343106985
LogScore ENTROPY: -313.0346428445288
LogScore AIC: -324.0346428445288

Time taken to build model: 0.05 seconds
```

[ Τα παραπάνω περιγράφουν τα χαρακτηριστικά του ταξινομητή, καθώς και τον χρόνο εκτέλεσής του ]

=== Stratified cross-validation ===  
=== Summary ===

|                                  |           |           |
|----------------------------------|-----------|-----------|
| Correctly Classified Instances   | 95        | 83.3333 % |
| Incorrectly Classified Instances | 19        | 16.6667 % |
| Kappa statistic                  | 0.6667    |           |
| Mean absolute error              | 0.2131    |           |
| Root mean squared error          | 0.38      |           |
| Relative absolute error          | 42.6043 % |           |
| Root relative squared error      | 75.9688 % |           |
| Total Number of Instances        | 114       |           |

[ Τα παραπάνω δίνουν τα επίπεδα λάθους, όταν εφαρμόζουμε τον classifier. Μας λέει ότι είχαμε 95 σωστές προβλέψεις (από τα 114 στοιχεία, ποσοστό 83.3%), και 19 λάθος (ή ποσοστό 16,6%) ].

=== Detailed Accuracy By Class ===

| TP Rate       | FP Rate | Precision | Recall | F-Measure | ROC Area | Class |
|---------------|---------|-----------|--------|-----------|----------|-------|
| 0.93          | 0.263   | 0.779     | 0.93   | 0.848     | 0.869    | Easy  |
| 0.737         | 0.07    | 0.913     | 0.737  | 0.816     | 0.869    | Hard  |
| Weighted Avg. | 0.833   | 0.167     | 0.846  | 0.833     | 0.832    | 0.869 |

=== Confusion Matrix ===

```
a b <-- classified as
53 4 | a = Easy
15 42 | b = Hard
```

[ Τα παραπάνω, περιγράφουν ποσοστά σωστής πρόβλεψης για κάθε class, π.χ. 93% TP Rate (True Positive) ταξινομήσεις για instances που ανήκουν στην εύκολη εικόνα και ταξινομήθηκαν σωστά και 26,3% FP Rate (False Positive) που ταξινομήθηκαν στο Easy, ενώ ήταν από άλλο task ή 53 από τα 57 στοιχεία σωστά ταξινομημένα και 4 λάθος ταξινομημένα στην class b=Hard. Επίσης 73.7% ορθές προβλέψεις για τη δύσκολη εικόνα ή 42 από τα 57 στοιχεία σωστά ταξινομημένα και 15 λάθος ταξινομημένα στην class a=Easy].



Όπου στα προηγούμενα βλέπουμε τη λέξη Easy, πρέπει να αντιλαμβανόμαστε την εύκολη εκπαιδευτική διαδικασία, ενώ όπου βλέπουμε τη λέξη Hard πρέπει να αντιλαμβανόμαστε τη δύσκολη.



## 6. ΠΕΙΡΑΜΑΤΙΚΑ ΑΠΟΤΕΛΕΣΜΑΤΑ – ΣΧΟΛΙΑΣΜΟΣ - ΣΥΜΠΕΡΑΣΜΑΤΑ

### 6.1 Εντοπισμός Στάσιμων Σημείων και Ατράκτων Στάσιμων κυμάτων

Στα πειραματικά αποτελέσματα που ακολουθούν θα διαπιστώσουμε ότι μπορέσαμε να εντοπίσουμε σημεία του ηλεκτροεγκεφαλογραφήματος τα οποία είναι σταθερά. Επίσης εντοπίστηκαν άτρακτοι, χαρακτηριστικές των στάσιμων κυμάτων.

Ως είσοδο των πειραμάτων μας χρησιμοποιήσαμε ηλεκτροεγκεφαλογραφικά σήματα, τα οποία λάβαμε από άτομα τα οποία βρίσκονταν σε φάση χαλάρωσης. Πηγή των δεδομένων ήταν προσωπική συλλογή του επιβλέποντα καθηγητή της διατριβής κ. Μάριου Πούλου. Επίσης χρησιμοποιήθηκαν και τα ΗΕΓ από το [171], που περιγράψαμε στην παράγραφο 5.1.


Έξι ΗΕΓ από άνδρες και έξι ΗΕΓ από γυναίκες συμμετείχαν σε αυτό το πείραμα. Η διάρκεια των ΗΕΓ ήταν περίπου 46 δευτερόλεπτα (46.000 msec). Τα αρχεία εισόδου αποτελούνται από 23.000 σημεία (1 σημείο / 2 msec). Για την υλοποίηση της διαδικασίας που περιγράφουμε στο 2.1 δημιουργήσαμε μια διαδικασία, την οποία εκτελέσαμε στο Matlab. Η διαδικασία είχε ως είσοδο 2 παραμέτρους. Η πρώτη παράμετρος ( $k$ ) είναι ο αριθμός των παραθύρων (αριθμός τμημάτων) του ηλεκτροεγκεφαλογραφήματος, τα οποία χρησιμοποιήσαμε. Η δεύτερη παράμετρος ( $w$ ) είναι το μέγεθος του παραθύρου (μήκος του τμήματος). Όταν ο αριθμός των παραθύρων είναι πάνω από 1 ( $k > 1$ ), έχουμε αλληλεπικάλυψη των χρησιμοποιούμενων σημείων (για παράδειγμα, με μήκος παραθύρου 20 και ξεκινώντας από το σημείο 5000, τα αλληπάλλληλα τμήματα αποτελούνται από τα εξής σημεία : 5000 ... 5020, 5001 ... 5021, 5002 ... 5022, κλπ.). Εκτελέσαμε τα πειράματα με διάφορους συνδυασμούς των δύο παραμέτρων ( $k$  και  $w$ ) και λάβαμε πάρα πολλά αποτελέσματα που παρουσιάζουμε παρακάτω. Ως επί το πλείστον χρησιμοποιήσαμε τμήματα των 20 σημείων ( $w=20$ ). Από ένα τέτοιο δείγμα, μήκους 20 σημείων, απομονώσαμε

28 συντελεστές αυτοσυσχέτισης ACC {D} (περιγράφεται η διαδικασία αναλυτικά στο 2.1).


Όπως είπαμε στην παράγραφο 2.1, πρέπει να υπολογίσουμε τους συντελεστές του πολυωνύμου παρεμβολής  $p(x)$  (εξίσωση 8 – Interpolation Polynomial), έξι βαθμών ελευθερίας, προκειμένου να επιτευχθεί καλύτερη προσαρμογή του  $p(x(i))$  στα  $C(i)$ , όπου  $x(i)$  είναι τα στοιχεία στον οριζόντιο άξονα (χρόνος ή σημεία) και  $C(i)$  είναι οι συντελεστές αυτοσυσχέτισης ACC. Για να το πετύχουμε αυτό, χρησιμοποιήσαμε τη συνάρτηση του Matlab `polyfit` [158].

$$p = \text{polyfit}(x, s, n) \quad (10)$$

Στην *Εικόνα 39* βλέπουμε τους συγκεκριμένους συντελεστές



**Εικόνα 39:** Συντελεστές του Πολυωνύμου παρεμβολής



**Εικόνα 40:** Γραφική αναπαράσταση του Πολυωνύμου n-οστού βαθμού evaluated at x (eq. 9)


Στη συνέχεια, προκειμένου να βρούμε ακριβώς το γράφημα το οποίο καλύτερα ταιριάζει στους συντελεστές του πολυωνύμου παρεμβολής, για κάθε στοιχείο του οριζόντιου άξονα (x) υπολογίζουμε το αντίστοιχο στοιχείο στον κάθετο άξονα (Y), σύμφωνα με την εξίσωση

$$y = p_1 x^n + p_2 x^{n-1} + \dots + p_n x + p_{n+1}$$


όπου  $p_i$  είναι το πολυώνυμο παρεμβολής που υπολογίσαμε προηγουμένως. Για κάθε τιμή του x στον οριζόντιο άξονα (χρόνος ή σημείο), η συνάρτηση `polyval` του Matlab επιστρέφει την τιμή ενός πολυωνύμου n-ιοστού βαθμού evaluated at x.

$$p = \text{polyval}(p, x) \quad (11)$$

Στην *Εικόνα 40* μπορούμε να δούμε το γράφημα που προκύπτει από τη διαδικασία που περιγράφηκε προηγουμένως. Το διάγραμμα που βλέπουμε στην *Εικόνα 40* αντιστοιχεί στην απεικόνιση του πολωνύμου της εξίσωσης (eq. 9), το οποίο είναι το αποτέλεσμα της εκτέλεσης της συνάρτησης `polyval` για  $k=1$  και  $w=20$  για έναν άνδρα (υποκείμενο εξέτασης).



**Εικόνα 41:** Αναπαράσταση πολωνύμου (eq. 9) για μια γυναίκα (αριστερά) και έναν άνδρα (δεξιά)



**Εικόνα 42:** Πολυωνυμική αναπαράσταση σταθερών σημείων ενός άνδρα ( $k = 10, w = 20$ )

Στην *Εικόνα 41* μπορούμε να δούμε μια παρόμοια αναπαράσταση του ίδιου πολυωνύμου από το Ηλεκτροεγκεφαλογράφημα μιας γυναίκας και ενός ακόμη άνδρα.


Αν αυξήσουμε τον αριθμό των δειγμάτων σε  $k = 10$  παίρνουμε την αναπαραστάση της *Εικόνα 42*. Η αναπαράσταση που παίρνουμε, όπως είπαμε προηγουμένως, έχει αλληλεπικαλυπτόμενα σημεία.

Στη *Εικόνα 42* επίσης, μπορούμε ξεκάθαρα να ξεχωρίσουμε τα σημεία στα οποία παρουσιάζεται στασιμότητα. Στην εικόνα φαίνονται ξεκάθαρα τα σημεία καθώς και οι γνωστές χαρακτηριστικές άτρακτοι των στάσιμων κυμάτων. Τα σημεία, όπως είναι προφανές έχουν σχεδόν μηδενικό πλάτος κίνησης.


Στο σήμα που αντιστοιχεί σε γυναίκα υποκείμενο, χρειάστηκε να αυξήσουμε το μέγεθος του δείγματος, προκειμένου να βρούμε σημεία στα οποία να εμφανίζεται στασιμότητα.

Στην *Εικόνα 43*, στο πρώτο διάγραμμα το  $k$  είναι ίσο με 10 ( $k = 10$ ), ενώ το παράθυρο  $w$  είναι ίσο με 20 ( $w=20$ ). Ως τμήμα του σήματος πήραμε τυχαία διάφορα μέρη του. Το συγκεκριμένο διάγραμμα αντιστοιχεί στα σημεία από


5,000 έως 5,500. Στο πρώτο διάγραμμα τα σταθερά σημεία δε διακρίνονται εύκολα. Στο δεύτερο διάγραμμα της ίδιας εικόνας 5, το  $k$  είναι ίσο με 10, ενώ το  $w$  είναι ίσο με 30 και ως τμήμα του σήματος πάλι τυχαία πήραμε τα σημεία από 3,000 μέχρι 5,500 (αυξήσαμε το μήκος του υπό εξέταση τμήματος). Σε αυτήν τη δεύτερη εικόνα τα σταθερά σημεία είναι εύκολα ευδιάκριτα καθώς και οι χαρακτηριστικές άτρακτοι των στάσιμων κυμάτων.



**Εικόνα 43:** Πολυωνυμική αναπαράσταση σταθερών σημείων μιας γυναίκας (5000-5500 και 3000-5500 points)



**Εικόνα 44:** Πρότυπο Στάσιμου Κύματος με τις χαρακτηριστικές ατράκτους



**Εικόνα 45:** Στάσιμα κύματα σε 6 EEGs ανά άτομο (5 άτομα)



Στην *Εικόνα 45* μπορούμε να δούμε 6 EEGs ανά άτομο, κάθε ένα από τα οποία αναπαρίσταται με διαφορετικό χρώμα και συνολικά για 5 άτομα. Στην ίδια εικόνα μπορούμε να έχουμε μια πιο προσεκτική προσέγγιση των στάσιμων κυμάτων. Ένα πρότυπο στάσιμου κύματος δεν είναι στην πραγματικότητα ένα κύμα, αλλά μάλλον ένα μοτίβο από ένα κύμα. Έτσι, δεν αποτελείται από όρη και κοιλάδες, αλλά μάλλον από κόμβους και αντι-κόμβους. Με άλλα λόγια, δημιουργούνται οι γνωστές άτρακτοι των στάσιμων κυμάτων. Το πρότυπο αυτό είναι το αποτέλεσμα της παρεμβολής δύο κυμάτων (παραγωγή κόμβων και αντι-κόμβων). Οι παράμετροι αυτού του προτύπου εμφανίζονται στην *Εικόνα 44*.

## 6.2 Συγχρονισμός με διαδικασία σταθερής περιόδου

Η μέθοδος που ακολουθήσαμε περιγράφηκε αναλυτικά στο 4.2. Στα πειραματικά αποτελέσματα που ακολουθούν, δημιουργήσαμε πρότυπο και από κάποιο μέρος του ΗΕΓ αλλά σε κάποιες περιπτώσεις δημιουργήσαμε πρότυπο από ένα απλό τυχαίο αριθμητικό σύνολο. Το αριθμητικό σύνολο περιείχε ψευδοτυχαίες τιμές  $Y_n$ , όπου  $Y \in R$ . Το αριθμητικό σύνολο λήφθηκε από τη συνάρτηση «randn» του Matlab. Η συνάρτηση αυτή παράγει κανονικά κατανοημένους ψευδοτυχαίους αριθμούς. Σύμφωνα με την παράγραφο 4.2., στο σημείο που αναφέρονται οι συντελεστές αυτοσυσχέτισης (Auto-Correlation Coefficients - ACC) μεταβάλλουμε το  $k$  από 2 έως 81.

Ένα παράδειγμα τέτοιων δεδομένων είναι το εξής (38) :

$$Y_n = [0.3861, 0.4737, -0.3852, \dots, -1.14701, 1.9662, 0.2326] \quad (38)$$

### A. Μια επαναλαμβανόμενη πειραματική διαδικασία

Σε αυτό το σημείο της πειραματικής διαδικασίας, μια επαναλαμβανόμενη διαδικασία αλλάζει μόνιμα τις τιμές των  $n$  (βαθμός πολωνύμου),  $m$  (παράθυρο) και  $k$  (πλήθος τμημάτων σήματος). Αυτή η ενέργεια εφαρμόζεται μέχρι ο συνδυασμός των τιμών των  $n$ ,  $m$  και  $k$  να ικανοποιεί την εξίσωση (30).

Η ερμηνεία των πειραματικών αποτελεσμάτων έδειξε ότι η σταθερές εγκάρσιες καμπύλες επιτυγχάνονται, όταν τα υπό διερεύνηση μικρά σύνολα δεδομένων αποτελούνται από έξι τμήματα  $k = 6$  και το παράθυρο του τμήματος που δείχνει τον βαθμό ασυμμετρίας (βλέπε εξίσωση 28) γίνεται 2 ( $m = 2$ ). Τέλος, ένα 6ου βαθμού πολυώνυμο  $p(x)$  ( $n = 6$ ) θα μπορούσε να θεωρηθεί ότι ταιριάζει καλύτερα στο πολυώνυμο που περιγράφεται ως  $C_m$  (εξίσωση 29). Το παραγόμενο πολυώνυμο είναι γνωστό ως «Πολυώνυμο Παρεμβολής». Το αποτέλεσμα που συμβολίζεται με  $p$  στην εξίσωση 31, είναι ένα διάνυσμα γραμμή μήκους  $n + 1$  που περιέχει τους συντελεστές του πολυωνύμου της εξίσωσης 39 (από εξίσωση 33) κατά φθίνουσα σειρά.

$$p(x) = p_1 x^6 + p_2 x^5 + \dots + p_5 x^1 + p_6 \quad (39)$$

$$p(x_i) = C_i \text{ για όλα τα } i \in \{0, 1, \dots, 6\}$$

Η επίλυση του συστήματος της γραμμικής εξίσωσης (39), η οποία δίνει τους 6

$$\sum_{k=1}^6 p_k$$

συντελεστές, επιτυγχάνεται σύμφωνα με μετασχηματισμό της εξίσωσης 31 που απεικονίζεται στην εξίσωση 40.

$$\vec{p} = \begin{bmatrix} p_6 \\ \dots \\ p_1 \end{bmatrix} = \frac{\begin{bmatrix} x_1^6 & \dots & x_1 & 1 \\ \dots & \dots & \dots & \dots \\ \dots & \dots & \dots & \dots \\ x_6^6 & \dots & x_6 & 1 \end{bmatrix}}{\begin{bmatrix} D_1 \\ \dots \\ D_6 \end{bmatrix}} \quad (40)$$

Στη συνέχεια, παράγουμε ένα διάνυσμα γραμμή

$$\vec{X} \text{ of } N = 100$$

με γραμμικά ισαπέχοντα σημεία μεταξύ  $x_0$  και  $x_6$ . Στη συνέχεια, χρησιμοποιώντας το σφάλμα πρόβλεψης το οποίο εκτιμά η DELTA [83], το οποίο είναι η τυπική απόκλιση του σφάλματος στην πρόβλεψη μιας μελλοντικής παρατήρησης στο  $\vec{X}$ , και τότε η εξίσωση 32 μετασχηματίζεται στην 41.

$$\vec{C}_{100} = \frac{1}{100 \times \log\left(\frac{x_{100}}{100}\right) + 1} \quad (41)$$

#### B. Πειραματική Σύγκλιση Σταθερής Περιόδου

Σε αυτό το στάδιο, εφαρμόζοντας τις τιμές ( $n = 2$ ,  $m = 6$  και  $k = 6$ ) της προαναφερθείσας επαναλαμβανόμενης διαδικασίας, παράγονται τρία (3) σταθερά σημεία διασταύρωσης (τομής) για κάθε εκτέλεση των υπολογισμένων


$\vec{C}_{100}$  συντελεστών ACC. Πιο συγκεκριμένα, τα σταθερά σημεία τομής καθορίζονται στα σημεία A, B και C, που αντιστοιχούν στις θέσεις 4, 5 και 6 του μικρού συνόλου δεδομένων το οποίο μελετάμε. Επιπλέον, στην *Εικόνα 46* παρατηρείται σταθερή περίοδος για τα σημεία τομής. Η απόσταση μεταξύ A και B είναι ίδια με την απόσταση μεταξύ B και C. Αυτή η παρατήρηση οδηγεί στο επόμενο αντικείμενο αυτής της έρευνας, το οποίο είναι η μέτρηση των μηκών μεταξύ δύο (2) τμημάτων συγχρονισμού.

Μέχρι τώρα διαπιστώσαμε δύο μοτίβα (patterns - βλέπε *Εικόνα 47* και *Εικόνα 48*) ασύγχρονων καμπυλών. Η βασική ιδέα της μέτρησης του συγχρονισμού επικεντρώνεται στην εφαρμογή της εξίσωσης


$$\sigma = \sqrt{E\left[\left\{\left(p'_w - p'_{w-1}\right) - \mu\right\}^2\right]},$$

στην οποία η μέτρηση της απόστασης κάθε υπό διερεύνηση καμπύλης ανάμεσα σε ένα ή δύο πρότυπα (patterns), τα οποία παράγονται αρχικά με τη μέθοδο που περιγράφεται στο 4.1, δημιουργεί μια απόφαση για ομαδοποίηση (clustering). Ως παράδειγμα της προαναφερθείσας μέτρησης, μπορούμε να δούμε την εκχώρηση σε μια κατηγορία (πρότυπο A ή B), η οποία υποδεικνύει τον πιθανό συγχρονισμό που απεικονίζεται στις *Εικόνα 49* και *Εικόνα 50*, με τη χρήση 50 τεμνόμενων καμπυλών.


Όπως μπορούμε να δούμε στην *Εικόνα 50*, η ανωτερότητα του προτύπου A στον τομέα των συνεχών επαναλήψεων είναι προφανής, ειδικά στην ακολουθία (27-33) των καμπυλών (βλέπε *Εικόνα 50*).




**Εικόνα 46:** Απεικόνιση σταθερών σημείων κατά τη διαδικασία εύρεσης τομών από regression έξι πολυνύμων μέσω του αλγορίθμου ACC για μικρό σετ δεδομένων ( $k=6$ )



**Εικόνα 47:** Καμπύλη του μοτίβου A



**Εικόνα 48:** Καμπύλη του μοτίβου B



**Εικόνα 49:** Απεικόνιση σταθερών σημείων με τη χρήση 50 τεμνόμενων καμπυλών

```
>> sorder'  
ans =  
  
Columns 1 through 23  
1 2 2 2 1 1 2 1 2 2 1 1 2 1 2 1  
  
Columns 24 through 46  
1 1 2 1 1 1 1 1 1 1 2 1 1 1 2 1  
  
Columns 47 through 50  
2 1 1 1
```

**Εικόνα 50:** Τα αποτελέσματα ομαδοποίησης των τεμνόμενων καμπυλών της **Εικόνα 49**

### 6.3 Αλγοριθμικά μοντέλα κατηγοριοποίησης με δείκτες

Στην παράγραφο αυτή παρουσιάζουμε τα αποτελέσματα από την επεξεργασία των δεδομένων, όπως παρουσιάστηκε στην παράγραφο 4.3 και επιπλέον την κατηγοριοποίηση των δεικτών και την εξαγωγή των κατάλληλων αλγορίθμων για την κατάλληλη πρόβλεψη της δυσκολίας που αντιμετωπίζει ο εγκέφαλος σε μια εκπαιδευτική διαδικασία.

Τα χαρακτηριστικά που χρησιμοποιήθηκαν για τον ταξινομητή WEKA ήταν 28 κανάλια, ενώ οι κλάσεις ήταν Hard και Easy, ανάλογα με τη δυσκολία που αντιμετωπίζει το άτομο κατά τη διάρκεια της εκπαιδευτικής διαδικασίας.

Το υπολογιστικό σύστημα που χρησιμοποιήθηκε, για να γίνουν τα πειράματα ήταν ένα laptop με επεξεργαστή i3 hyperthreting και μνήμη 4 GB.

Η αξιολόγηση των αποτελεσμάτων για όλους τους δείκτες έγινε με δύο τρόπους. Ο πρώτος ήταν με διαγραμματικές τεχνικές, όπου παρουσιάστηκαν και σχολιάστηκαν τα αποτελέσματα μέσω διαγραμμάτων.

Ο δεύτερος τρόπος ήταν με τη χρήση των δεικτών Sensitivity (Ευαισθησίας) και Specificity (Ειδικότητας). Πιο συγκεκριμένα, Sensitivity είναι ([99] και [5]) η αναλογία των θετικών περιπτώσεων που έχουν αναγνωριστεί σωστά από τον αλγόριθμο, ενώ η Specificity είναι το ποσοστό των αρνητικών περιπτώσεων που

εντοπίστηκαν σωστά από τον αλγόριθμο. Ευαισθησία και Ειδικότητα είναι στατιστικές μετρήσεις της απόδοσης ενός αλγόριθμου, και είναι πολύ γνωστοί δείκτες εμπιστοσύνης σε στατιστικές λειτουργίες και διαδικασίες ταξινόμησης.

Sensitivity (Ευαισθησία) ονομάζεται επίσης το αληθινό θετικό ποσοστό (ή το ποσοστό ανάκλησης σε ορισμένους τομείς), το οποίο μετρά το ποσοστό των θετικών πραγματικών αποτελεσμάτων, τα οποία κατατάσσονται και αναγνωρίζονται σωστά ως τέτοια. Στην περίπτωση μας, είναι το ποσοστό των εικόνων που χαρακτηρίζονται ως εύκολες και αναγνωρίζονται και κατατάσσονται ορθά ως εύκολες από τον αλγόριθμο.

Specificity (Εξειδίκευση), ονομάζεται το πραγματικό αρνητικό ποσοστό που μετρά το ποσοστό των αρνητικών αποτελεσμάτων, που ορθά αναγνωρίζονται ως τέτοια (π.χ. το ποσοστό των εικόνων που χαρακτηρίζονται δύσκολες και αναγνωρίζονται ορθά ως μη εύκολες), και είναι συμπληρωματικό προς το ποσοστό ψευδώς θετικών.

Ένα τέλειος δείκτης πρόβλεψης θα πρέπει να περιγράφεται ως 100% ευαίσθητος (π.χ., όλα τα εύκολα ταυτοποιούνται ως εύκολα) και 100% ειδικός (π.χ. όλα τα δύσκολα δεν αναγνωρίζονται ως εύκολα). Ωστόσο θεωρητικά, κάθε δείκτης πρόγνωσης παρουσιάζει τουλάχιστον ένα ελάχιστο ποσοστό σφάλματος, το οποίο είναι γνωστό ως το ποσοστό σφάλματος του Bayes.

Οι Δείκτες Sensitivity (Ευαισθησίας) και Specificity (Ειδικότητας) υπολογίζονται από τις παρακάτω εξισώσεις (42 ) και (43 ) :

$$Sensitivity = \frac{a}{a + c} \quad (42)$$



$$Specificity = \frac{d}{b + d} \quad (43)$$

Όπου  $a$  είναι οι εικόνες που χαρακτηρίζονται ως εύκολες, οι οποίες ορθά χαρακτηρίστηκαν ως εύκολες και  $c$  οι υπόλοιπες από αυτές, ενώ  $d$  είναι οι εικόνες που χαρακτηρίζονται ως δύσκολες και οι οποίες ορθά αναγνωρίστηκαν ως μη εύκολες και  $b$  οι υπόλοιπες από αυτές.

### **6.3.1 Λεπτομέρειες της Ταξινόμησης**

Στη συνέχεια εκτελέσαμε πειράματα στο λογισμικό εξόρυξης γνώσης και κατηγοριοποίησης WEKA, χρησιμοποιώντας διάφορους τύπους διανυσματικών δεικτών με διάφορους αλγόριθμους ταξινόμησης, όπως τους περιγράψαμε στο 3ο κεφάλαιο. Από τα αποτελέσματα βγάλαμε πολύ χρήσιμα συμπεράσματα για την αξία του ταξινομητή και για τη δυνατότητα πρόβλεψης της δυσκολίας που αισθάνεται ένα άτομο κατά τη διάρκεια της εκπαιδευτικής διαδικασίας.

Σε κάποια φάση των πειραμάτων μας, πειραματιστήκαμε και με τον αριθμό των χαρακτηριστικών (attributes), για τα οποία διαπιστώσαμε το εξής σημαντικό: όταν αυξάνεται ο αριθμός τους, αυξάνεται και η προβλεπτική ικανότητα των διανυσματικών δεικτών. Ως χαρακτηριστικά στην πειραματική διαδικασία εννοούμε τον αριθμό των σημάτων που καταγράφονται μέσω των ηλεκτροδίων. Οι δείκτες δηλαδή που μετράμε, έχουν πολύ καλύτερη προβλεπτική αποτελεσματικότητα, όταν αυξάνεται ο αριθμός των χαρακτηριστικών. Δηλαδή, εάν χρησιμοποιούμε 2, 4, 6 κανάλια η προβλεπτική ικανότητα των δεικτών είναι πάρα πολύ κακή. Δοκιμάσαμε με αρκετούς διαφορετικούς συνδυασμούς αριθμού καναλιών και καταλήξαμε ότι πρέπει να πάρουμε τον μεγαλύτερο δυνατό αριθμό καταγραφών, άρα το μεγαλύτερο δυνατό αριθμό ηλεκτροδίων.

Στις επόμενες παραγράφους δίνουμε τις λεπτομέρειες της διαδικασίας ταξινόμησης :

### Μοντέλο Ταξινόμησης (Classification Test mode)

Το μοντέλο κατηγοριοποίησης που χρησιμοποιήθηκε στα πειράματά μας ήταν το k-fold cross-validation και πιο συγκεκριμένα το 10-fold cross-validation test model [65]. Η μέθοδος αυτή ονομάζεται και «μέθοδος της επαναλαμβανόμενης τυχαίας υπο-δειγματοληψίας». Σε αυτό το μοντέλο, το προς εξέταση σήμα χωρίζεται τυχαία σε 10 ίσα υποσήματα. Από τα 10 επιμέρους σήματα, ένα ενιαίο υπο-σήμα χρησιμοποιείται ως «δεδομένα επικύρωσης» για το υπό δοκιμή μοντέλο και τα υπόλοιπα 9 υπο-σήματα χρησιμοποιούνται ως δεδομένα εκπαίδευσης. Η διαδικασία διασταυρούμενης αξιολόγησης (cross – validation prosedure) επαναλαμβάνεται 10 φορές (η διαδικασία ονομάζεται «πτυχώσεις»-«folds»), με κάθε ένα από τα 10 επιμέρους σήματα να χρησιμοποιούνται ακριβώς ως δεδομένα αξιολόγησης. Τα αποτελέσματα από τις 10 πτυχώσεις μπορούν στη συνέχεια να δώσουν έναν μέσο όρο (η διαδικασία αυτή ονομάζεται «διασύνδεση» - «combination»), έτσι ώστε να παραχθεί μια ενιαία εκτίμηση. Το πλεονέκτημα της μεθόδου της επαναλαμβανόμενης τυχαίας υπο-δειγματοληψίας είναι ότι όλες οι παρατηρήσεις που χρησιμοποιούνται τόσο για την εκπαίδευση όσο και για αξιολόγηση καθώς και κάθε παρατήρηση χρησιμοποιούνται για την αξιολόγηση ακριβώς μια φορά [65]. Η μέθοδος k-fold cross validation είναι η πιο συχνά χρησιμοποιούμενη για ερευνητικούς σκοπούς. Η παράμετρος k όμως είναι ένα ζητούμενο. Σε στρωματοποιημένη k-fold, οι πτυχώσεις (τα k folds) επιλέγονται, έτσι ώστε η μέση τιμή απόκρισης να είναι περίπου ίση σε όλες τις πτυχώσεις. Στην περίπτωση μιας διχοτομικής ταξινόμησης, αυτό σημαίνει ότι κάθε πτυχή θα περιέχει περίπου τις ίδιες αναλογίες των δύο τύπων των κλάσεων. Χρησιμοποιήσαμε την 10-folds cross validation, σε όλα τα πειράματά και με όλους τους αλγορίθμους.

### Μορφή του αρχείου ARFF (αρχείο που διαβάζει το WEKA)

Σε όλα τα αρχεία arff χρησιμοποιήσαμε τις ίδιες δύο κλάσεις, την Easy και την Hard, οι οποίες στην ουσία αντιπροσωπεύουν τα tasks μας. Είναι προφανές ότι η

Easy κλάση αντιστοιχίζεται στην εύκολη εκπαιδευτική διαδικασία, ενώ η Hard στη δύσκολη.

Οι ταξινομητές που χρησιμοποιήθηκαν στην παρούσα εργασία αναφέρονται στην παράγραφο 5.5.3. Πιο συγκεκριμένα, χρησιμοποιήθηκαν οι BayesNet, JRip, NaiveBayesMultinomial, NaiveBayesSimple, DecisionTable, Part, Ridor, SMO, VFI, ZeroR, BFTree.

### 6.3.2 Δείκτης GFP

Στον Πίνακα 5 φαίνονται τα αποτελέσματα από την εξαγωγή του δείκτη GFP μετά την επεξεργασία τους με τους διάφορους αλγόριθμους του WEKA.

| Αλγόριθμοι            | Correctly classified instances | Incorrectly Classified Instances | root mean squared error | TP rates Weighted Avg. | FP rates Weighted Avg. |
|-----------------------|--------------------------------|----------------------------------|-------------------------|------------------------|------------------------|
| BayesNet              | 901                            | 99                               | 0,2939                  | 90,1%                  | 9,9%                   |
| JRip                  | 975                            | 25                               | 0,1558                  | 97,5%                  | 2,5%                   |
| NaiveBayesMultinomial | 805                            | 195                              | 0,4405                  | 80,5%                  | 19,5%                  |
| NaiveBayesSimple      | 860                            | 140                              | 0,3666                  | 86,0%                  | 14,0%                  |
| DecisionTable         | 934                            | 66                               | 0,2223                  | 93,4%                  | 6,6%                   |
| Part                  | 983                            | 17                               | 0,1304                  | 98,3%                  | 1,7%                   |
| Ridor                 | 974                            | 26                               | 0,1612                  | 97,4%                  | 2,6%                   |
| SMO                   | 980                            | 20                               | 0,1414                  | 98,0%                  | 2,0%                   |
| VFI                   | 934                            | 66                               | 0,2222                  | 93,4%                  | 6,6%                   |
| ZeroR                 | 500                            | 500                              | 0,5                     | 50,0%                  | 50,0%                  |
| BFTree                | 971                            | 29                               | 0,1641                  | 97,1%                  | 2,9%                   |

**Πίνακας 5:** Αποτελέσματα ταξινόμησης δεδομένων με δείκτη GFP


Από τον πίνακα βλέπουμε ότι παράγονται πολύ καλές κατηγοριοποιήσεις, όπως PART 98.3%, SMO 98.0%, JRip 97,5%, Ridor 97,4%, BFTree 97,1%. Ανάλογα με το ποσοστό ορθής πρόβλεψης της δυσκολίας, καλύτερος κατηγοριοποιητής αναδεικνύεται ο SMO, με ποσοστό ορθών προβλέψεων δυσκολίας στο 98% και με τον μικρότερο χρόνο παραγωγής του μοντέλου (Πίνακας 6) στα 50 msec.

Ισάξιος ταξινομητής του SMO αναδεικνύεται ο αλγόριθμος PART, με ποσοστό ορθών προβλέψεων δυσκολίας στο 98,3% αλλά με μεγαλύτερο χρόνο παραγωγής του μοντέλου στα 60 msec. Στην *Εικόνα 51* παρουσιάζουμε όλο το αποτέλεσμα της ταξινόμησης με τον SMO ("Stratified cross-validation" classification summary).


| Αλγόριθμοι            | Time taken to build model |
|-----------------------|---------------------------|
| BayesNet              | 0,03                      |
| JRip                  | 0,10                      |
| NaiveBayesMultinomial | 0,00                      |
| NaiveBayesSimple      | 0,00                      |
| DecisionTable         | 0,26                      |
| Part                  | 0,06                      |
| Ridor                 | 0,11                      |
| SMO                   | 0,05                      |
| VFI                   | 0,26                      |
| ZeroR                 | 0,00                      |
| BFTree                | 0,63                      |

*Πίνακας 6 : Χρόνος Δημιουργίας Μοντέλου δεδομένων με δείκτη GFP*


Επίσης στις εικόνες *Εικόνα 51*, *Εικόνα 52* και *Εικόνα 53* βλέπουμε μια αναπαράσταση με ραβδογράμματα των αποτελεσμάτων που παρουσιάζονται και στους *Πίνακας 5* και *Πίνακας 6*. Πιο συγκεκριμένα στην *Εικόνα 51* βλέπουμε την ικανότητα πρόβλεψης των ταξινομητών που χρησιμοποιήσαμε, ενώ στην εικόνα *Εικόνα 52* βλέπουμε το μέσο τετραγωνικό σφάλμα καθενός ταξινομητή και τέλος στην *Εικόνα 53* βλέπουμε τους χρόνους που χρειάστηκε το υπολογιστικό σύστημα, για να παράξει τα μοντέλα.



**Εικόνα 51:** Ικανότητα ορθής πρόβλεψης ταξινομητών για δεδομένα με δείκτη GFP



**Εικόνα 52:** Μέσο τετραγωνικό σφάλμα ταξινομητών για δεδομένα με δείκτη GFP



Εικόνα 53: Χρόνος δημιουργίας μοντέλου για δεδομένα με δείκτη GFP

| Stratified cross-validation                                      |         |         |                         |        |           |      |                     |
|------------------------------------------------------------------|---------|---------|-------------------------|--------|-----------|------|---------------------|
| Test mode: 10-fold cross-validation                              |         |         |                         |        |           |      |                     |
| SMO                                                              |         |         |                         |        |           |      |                     |
| Kernel used: Linear Kernel: $K(x,y) = \langle x,y \rangle$       |         |         |                         |        |           |      |                     |
| Classifier for classes: Easy_GFPs_1_SUBJECT, Hard_GFPs_1_SUBJECT |         |         |                         |        |           |      |                     |
| Binary SMO                                                       |         |         |                         |        |           |      |                     |
| Time taken to build model: 0.05 seconds                          |         |         |                         |        |           |      |                     |
| Correctly Classified Instances                                   | 980     | 98%     |                         |        |           |      |                     |
| Incorrectly Classified Instances                                 | 20      | 2%      |                         |        |           |      |                     |
| Kappa statistic                                                  | 0.96    |         |                         |        |           |      |                     |
| Mean absolute error                                              | 0.02    |         |                         |        |           |      |                     |
| Root mean squared error                                          | 0.1414  |         |                         |        |           |      |                     |
| Relative absolute error                                          | 4%      |         |                         |        |           |      |                     |
| Root relative squared error                                      | 28%     |         |                         |        |           |      |                     |
| Total Number of Instances                                        | 1000    |         |                         |        |           |      |                     |
| === Detailed Accuracy By Class ===                               |         |         |                         |        |           |      |                     |
|                                                                  | TP Rate | FP Rate | Precision               | Recall | F-Measure | ROC  | Area Class          |
|                                                                  | 0.976   | 0.016   | 0.984                   | 0.976  | 0.98      | 0.98 | Easy_GFPs_1_SUBJECT |
|                                                                  | 0.984   | 0.024   | 0.976                   | 0.984  | 0.98      | 0.98 | Hard_GFPs_1_SUBJECT |
| Weighted Avg                                                     | 0.98    | 0.02    | 0.98                    | 0.98   | 0.98      | 0.98 |                     |
| === Confusion Matrix ===                                         |         |         |                         |        |           |      |                     |
|                                                                  | a       | b       | <- classified as        |        |           |      |                     |
|                                                                  | 488     | 12      | a = Easy_GFPs_1_SUBJECT |        |           |      |                     |
|                                                                  | 8       | 492     | b = Hard_GFPs_1_SUBJECT |        |           |      |                     |

Εικόνα 54: Stratified cross-validation classification summary

### Sensitivity και Specificity για τον δείκτη GFP

Η Sensitivity και η Specificity για τον δείκτη GFP φαίνεται στον Πίνακα 7. Τα αποτελέσματα προκύπτουν από την εφαρμογή των τιμών που πήραμε κατά τον υπολογισμό του δείκτη GFP στις εξισώσεις (42) και (43).

| Algorithms            | Easy Identified as easy | Hard Identified as not easy | Sensitivity | Specificity | All Instances |
|-----------------------|-------------------------|-----------------------------|-------------|-------------|---------------|
| BayesNet              | 480                     | 421                         | 96,0%       | 84,2%       | 500           |
| JRip                  | 491                     | 484                         | 98,2%       | 96,8%       | 500           |
| NaiveBayesMultinomial | 500                     | 305                         | 100,0%      | 61,0%       | 500           |
| NaiveBayesSimple      | 490                     | 370                         | 98,0%       | 74,0%       | 500           |
| DecisionTable         | 471                     | 463                         | 94,2%       | 92,6%       | 500           |
| Part                  | 492                     | 491                         | 98,4%       | 98,2%       | 500           |
| Ridor                 | 487                     | 487                         | 97,4%       | 97,4%       | 500           |
| SMO                   | 488                     | 492                         | 97,6%       | 98,4%       | 500           |
| VFI                   | 471                     | 463                         | 94,2%       | 92,6%       | 500           |
| ZeroR                 | 500                     | 0                           | 100,0%      | 0,0%        | 500           |
| BFTree                | 487                     | 484                         | 97,4%       | 96,8%       | 500           |

Πίνακας 7 : Sensitivity και Specificity δεδομένων με δείκτη GFP

#### 6.3.3 Δείκτης Φασματικής Ισχύος (Power Spectral)

Στη συνέχεια πειραματιστήκαμε με τα διανύσματα, τα οποία προέκυψαν από τον δείκτη της Φασματικής Ισχύος, όπου τα αποτελέσματα ήταν αντίστοιχα. Και πάλι αυξάνοντας τον αριθμό των attributes είχαμε πολύ καλύτερες προβλέψεις από τους αλγόριθμους.

Συγκεντρωτικά τα αποτελέσματα φαίνονται στον παρακάτω Πίνακα 8.

| Αλγόριθμοι            | Correctly classified instances | Incorrectly Classified Instances | root mean squared error | TP rates Weighted Avg. | FP rates Weighted Avg. |
|-----------------------|--------------------------------|----------------------------------|-------------------------|------------------------|------------------------|
| BayesNet              | 632                            | 368                              | 0,3409                  | 63%                    | 37%                    |
| JRip                  | 958                            | 42                               | 0,404                   | 96%                    | 4%                     |
| NaiveBayesMultinomial | 690                            | 310                              | 0,2197                  | 69%                    | 31%                    |
| NaiveBayesSimple      | 710                            | 290                              | 0,1872                  | 71%                    | 29%                    |
| DecisionTable         | 934                            | 66                               | 0,2739                  | 93%                    | 7%                     |
| Part                  | 969                            | 31                               | 0,1595                  | 97%                    | 3%                     |
| Ridor                 | 958                            | 42                               | 0,1308                  | 96%                    | 4%                     |
| SMO                   | 975                            | 25                               | 0,17                    | 98%                    | 3%                     |
| VFI                   | 921                            | 79                               | 0,4754                  | 92%                    | 8%                     |
| ZeroR                 | 500                            | 500                              | 0,4754                  | 50%                    | 50%                    |
| BFTree                | 965                            | 35                               | 0,2109                  | 97%                    | 4%                     |


**Πίνακας 8 :** Αποτελέσματα ταξινόμησης δεδομένων με δείκτη Power Spectral

Από τους δείκτες της φασματικής ισχύος φαίνεται να έχουμε και εδώ αρκετούς ταξινομητές, οι οποίοι μπορούν να δώσουν σωστές προβλέψεις σε πολύ υψηλά ποσοστά. Εδώ πάνω από 90% σωστών προβλέψεων έχουμε με τους περισσότερους.


| Αλγόριθμοι            | Time taken to build model |
|-----------------------|---------------------------|
| BayesNet              | 0,06                      |
| JRip                  | 0,03                      |
| NaiveBayesMultinomial | 0,86                      |
| NaiveBayesSimple      | 1,03                      |
| DecisionTable         | 0,61                      |
| Part                  | 9,75                      |
| Ridor                 | 0                         |
| SMO                   | 0,89                      |
| VFI                   | 0,02                      |
| ZeroR                 | 0                         |
| BFTree                | 13,48                     |

**Πίνακας 9 :** Χρόνος Δημιουργίας Μοντέλου δεδομένων με δείκτη Power Spectral






Εικόνα 55: Ικανότητα ορθής πρόβλεψης ταξινομητών για δεδομένα με δείκτη Power Spectral



Εικόνα 56: Μέσο τετραγωνικό σφάλμα ταξινομητών για δεδομένα με δείκτη Power Spectral



Εικόνα 57: Χρόνος δημιουργίας μοντέλου για δεδομένα με δείκτη Power Spectral

Ως προς το τετραγωνισκό σφάλμα αλλά και το χρόνο δημιουργίας του μοντέλου, καλύτερος ταξινομητής αναδεικνύεται και πάλι ο SMO.

Sensitivity και Specificity για τον δείκτη Power Spectral

Η Sensitivity και η Specificity για τον δείκτη Power Spectra φαίνεται στον Πίνακα 10. Τα αποτελέσματα προκύπτουν από την εφαρμογή των τιμών που πήραμε κατά τον υπολογισμό του δείκτη PS στις εξισώσεις (42) και (43).

| Algorithms            | Easy Identified as easy | Hard Identified as not easy | Sensitivity | Specificity | All Instances |
|-----------------------|-------------------------|-----------------------------|-------------|-------------|---------------|
| BayesNet              | 310                     | 322                         | 62,0%       | 64,4%       | 500           |
| JRip                  | 482                     | 476                         | 96,4%       | 95,2%       | 500           |
| NaiveBayesMultinomial | 335                     | 355                         | 67,0%       | 71,0%       | 500           |
| NaiveBayesSimple      | 339                     | 371                         | 67,8%       | 74,2%       | 500           |
| DecisionTable         | 475                     | 459                         | 95,0%       | 91,8%       | 500           |
| Part                  | 491                     | 478                         | 98,2%       | 95,6%       | 500           |
| Ridor                 | 490                     | 468                         | 98,0%       | 93,6%       | 500           |
| SMO                   | 496                     | 479                         | 99,2%       | 95,8%       | 500           |
| VFI                   | 469                     | 452                         | 93,8%       | 90,4%       | 500           |
| ZeroR                 | 500                     | 0                           | 100,0%      | 0,0%        | 500           |
| BFTree                | 485                     | 480                         | 97,0%       | 96,0%       | 500           |

Πίνακας 10 : Sensitivity και Specificity δεδομένων με δείκτη Power Spectral

### 6.3.4 Δείκτης ERSP

Στη συνέχεια πειραματιστήκαμε με τα διανύσματα τα οποία προέκυψαν από τον δείκτη ERSP, όπου τα αποτελέσματα ήταν και πάλι πολύ ικανοποιητικά. Και πάλι αυξάνοντας τον αριθμό των καναλιών είχαμε πολύ καλύτερες προβλέψεις από τους αλγόριθμους. Παρακάτω παραθέτουμε μόνο τα αποτελέσματα με τον μέγιστο αριθμό ηλεκτροδίων που δοκιμάσαμε.

Συγκεντρωτικά τα αποτελέσματα φαίνονται στον παρακάτω πίνακα.

| Αλγόριθμοι            | Correctly classified instances | Incorrectly Classified Instances | root mean squared error | TP rates Weighted Avg. | FP rates Weighted Avg. |
|-----------------------|--------------------------------|----------------------------------|-------------------------|------------------------|------------------------|
| BayesNet              | 745                            | 255                              | 0,3409                  | 75%                    | 26%                    |
| JRip                  | 961                            | 39                               | 0,404                   | 96%                    | 4%                     |
| NaiveBayesMultinomial | 782                            | 218                              | 0,2197                  | 78%                    | 22%                    |
| NaiveBayesSimple      | 824                            | 176                              | 0,1872                  | 82%                    | 18%                    |
| DecisionTable         | 931                            | 69                               | 0,2739                  | 93%                    | 7%                     |
| Part                  | 972                            | 28                               | 0,1595                  | 97%                    | 3%                     |
| Ridor                 | 959                            | 41                               | 0,1308                  | 96%                    | 4%                     |
| SMO                   | 983                            | 17                               | 0,17                    | 98%                    | 2%                     |
| VFI                   | 936                            | 64                               | 0,4754                  | 94%                    | 6%                     |
| ZeroR                 | 500                            | 500                              | 0,4754                  | 50%                    | 50%                    |
| BFTree                | 973                            | 27                               | 0,2109                  | 97%                    | 3%                     |

Πίνακας 11 : Αποτελέσματα ταξινόμησης δεδομένων με δείκτη ERSP

Από τον παραπάνω πίνακα προκύπτει ότι η χρήση των δεικτών ERSP δίνει άριστα αποτελέσματα ως προς την πρόβλεψη με πάρα πολλούς ταξινομητές. Ποσοστό πάνω από 95% σωστών προβλέψεων έχουν πολλοί αλγόριθμοι, με καλύτερο τον SMO, όπως προηγουμένως, με επιτυχία 98%. Για τον συγκεκριμένο ταξινομητή παραθέτουμε και τον Confusion Matrix του,


=== Confusion Matrix ===

```
a b <-- classified as
98 2 | a = Easy_ERSPs_1_SUBJECT
3 97 | b = Hard_ERSPs_1_SUBJECT
```


όπου φαίνεται να προβέπει σχεδόν με απόλυτη επιτυχία. Όπως φαίνεται και στην **Εικόνα 58**, προβλέπει σωστά τα 983 instances σε σύνολο 1000.

| Αλγόριθμοι            | Time taken to build model |
|-----------------------|---------------------------|
| BayesNet              | 0,09                      |
| JRip                  | 0,03                      |
| NaiveBayesMultinomial | 0,55                      |
| NaiveBayesSimple      | 0,49                      |
| DecisionTable         | 0,34                      |
| Part                  | 7,09                      |
| Ridor                 | 0                         |
| SMO                   | 0,5                       |
| VFI                   | 0,02                      |
| ZeroR                 | 0,02                      |
| BFTree                | 7,09                      |


Πίνακας 12 : Χρόνος Δημιουργίας Μοντέλου δεδομένων με δείκτη ERSP



Εικόνα 58: Ικανότητα ορθής πρόβλεψης ταξινομητών για δεδομένα με δείκτη ERSF



Εικόνα 59: Μέσο τετραγωνικό σφάλμα ταξινομητών για δεδομένα με δείκτη ERSF



Εικόνα 60: Χρόνος δημιουργίας μοντέλου για δεδομένα με δείκτη ERSP

Ως προς το τετραγωνικό σφάλμα αλλά και τον χρόνο δημιουργίας του μοντέλου, καλύτερος ταξινομητής αναδεικνύεται και πάλι ο SMO.

Sensitivity και Specificity για τον δείκτη ERSP

Η Sensitivity και η Specificity για τον δείκτη ERSP φαίνεται στον Πίνακα 13. Τα αποτελέσματα προκύπτουν από την εφαρμογή των τιμών που πήραμε κατά τον υπολογισμό του δείκτη ERSP στις εξισώσεις (42) και (43).

| Algorithms            | Easy Identified as easy | Hard Identified as not easy | Sensitivity | Specificity | All Instances |
|-----------------------|-------------------------|-----------------------------|-------------|-------------|---------------|
| BayesNet              | 410                     | 335                         | 82,0%       | 67,0%       | 500           |
| JRip                  | 491                     | 470                         | 98,2%       | 94,0%       | 500           |
| NaiveBayesMultinomial | 395                     | 387                         | 79,0%       | 77,4%       | 500           |
| NaiveBayesSimple      | 410                     | 414                         | 82,0%       | 82,8%       | 500           |
| DecisionTable         | 476                     | 455                         | 95,2%       | 91,0%       | 500           |
| Part                  | 496                     | 476                         | 99,2%       | 95,2%       | 500           |
| Ridor                 | 491                     | 468                         | 98,2%       | 93,6%       | 500           |
| SMO                   | 498                     | 485                         | 99,6%       | 97,0%       | 500           |
| VFI                   | 471                     | 465                         | 94,2%       | 93,0%       | 500           |

|        |     |     |        |       |     |
|--------|-----|-----|--------|-------|-----|
| ZeroR  | 500 | 0   | 100,0% | 0,0%  | 500 |
| BFTree | 486 | 487 | 97,2%  | 97,4% | 500 |

Πίνακας 13 : Sensitivity και Specifity δεδομένων με δείκτη ERSF

### 6.3.5 Συγκεντρωτική σύγκριση επίδοσης Ταξινομητών

Στην παράγραφο αυτή κάνουμε μια συγκεντρωτική παρουσίαση των διαφόρων ταξινομητών σε συνδυασμό με τους δείκτες που εξετάσαμε, με σκοπό να εξάγουμε το μοντέλο μας.

| Αλγόριθμοι            | ERSF<br>Correctly<br>classified<br>instances | GFP<br>Correctly<br>classified<br>instances | PS<br>Correctly<br>classified<br>instances |
|-----------------------|----------------------------------------------|---------------------------------------------|--------------------------------------------|
| BayesNet              | 745                                          | 901                                         | 632                                        |
| JRip                  | 961                                          | 975                                         | 958                                        |
| NaiveBayesMultinomial | 782                                          | 805                                         | 690                                        |
| NaiveBayesSimple      | 824                                          | 860                                         | 710                                        |
| DecisionTable         | 931                                          | 934                                         | 934                                        |
| Part                  | 972                                          | 983                                         | 969                                        |
| Ridor                 | 959                                          | 974                                         | 958                                        |
| SMO                   | 983                                          | 980                                         | 975                                        |
| VFI                   | 936                                          | 934                                         | 921                                        |
| ZeroR                 | 500                                          | 500                                         | 500                                        |
| BFTree                | 973                                          | 971                                         | 965                                        |


Πίνακας 14 : Αποτελέσματα σωστής ταξινόμησης όλων των δεικτών ανά αλγόριθμο

| Αλγόριθμοι            | ERSF<br>Incorrectly<br>Classified<br>Instances | GFP<br>Incorrectly<br>Classified<br>Instances | PS<br>Incorrectly<br>Classified<br>Instances |
|-----------------------|------------------------------------------------|-----------------------------------------------|----------------------------------------------|
| BayesNet              | 255                                            | 99                                            | 368                                          |
| JRip                  | 39                                             | 25                                            | 42                                           |
| NaiveBayesMultinomial | 218                                            | 195                                           | 310                                          |
| NaiveBayesSimple      | 176                                            | 140                                           | 290                                          |
| DecisionTable         | 69                                             | 66                                            | 66                                           |
| Part                  | 28                                             | 17                                            | 31                                           |
| Ridor                 | 41                                             | 26                                            | 42                                           |
| SMO                   | 17                                             | 20                                            | 25                                           |
| VFI                   | 64                                             | 66                                            | 79                                           |
| ZeroR                 | 500                                            | 500                                           | 500                                          |
| BFTree                | 27                                             | 29                                            | 35                                           |

Πίνακας 15 : Αποτελέσματα λανθασμένης ταξινόμησης όλων των δεικτών ανά αλγόριθμο


| Αλγόριθμοι            | ERSP TP<br>rates<br>Weighted<br>Avg. | GFP TP<br>rates<br>Weighted<br>Avg. | PS TP<br>rates<br>Weighted<br>Avg. |
|-----------------------|--------------------------------------|-------------------------------------|------------------------------------|
| BayesNet              | 0,745                                | 0,901                               | 0,632                              |
| JRip                  | 0,961                                | 0,975                               | 0,958                              |
| NaiveBayesMultinomial | 0,782                                | 0,805                               | 0,69                               |
| NaiveBayesSimple      | 0,824                                | 0,86                                | 0,71                               |
| DecisionTable         | 0,931                                | 0,934                               | 0,934                              |
| Part                  | 0,972                                | 0,983                               | 0,969                              |
| Ridor                 | 0,959                                | 0,974                               | 0,958                              |
| SMO                   | 0,983                                | 0,98                                | 0,975                              |
| VFI                   | 0,936                                | 0,934                               | 0,921                              |
| ZeroR                 | 0,5                                  | 0,5                                 | 0,5                                |
| BFTree                | 0,973                                | 0,971                               | 0,965                              |

Πίνακας 16 : Αποτελέσματα επί τις εκατό σωστής ταξινόμησης όλων των δεικτών ανά αλγόριθμο




Εικόνα 61: Αποτελέσματα σωστής ταξινόμησης όλων των δεικτών ανά αλγόριθμο





Εικόνα 62: Αποτελέσματα λανθασμένης ταξινόμησης όλων των δεικτών ανά αλγόριθμο



Εικόνα 63: Αποτελέσματα επί τις εκατό σωστής ταξινόμησης όλων των δεικτών ανά αλγόριθμο

Ως προς το τετραγωνικό σφάλμα αλλά και τον χρόνο δημιουργίας του μοντέλου, καλύτερος ταξινομητής αναδεικνύεται και πάλι ο SMO.

### 6.3.6 Συγκεντρωτική σύγκριση Sensitivity και Specificity

Στην παράγραφο αυτή καταγράφουμε συγκεντρωτικά τα αποτελέσματα για τους τρεις δείκτες που αφορούν τους δύο δείκτες αξιολόγησης sensitivity και specificity.

| Algorithms            | ERSP<br>Easy<br>Identified<br>as easy | GFP Easy<br>Identified<br>as easy | PS Easy<br>Identified<br>as easy |
|-----------------------|---------------------------------------|-----------------------------------|----------------------------------|
| BayesNet              | 410                                   | 480                               | 310                              |
| JRip                  | 491                                   | 491                               | 482                              |
| NaiveBayesMultinomial | 395                                   | 500                               | 335                              |
| NaiveBayesSimple      | 410                                   | 490                               | 339                              |
| DecisionTable         | 476                                   | 471                               | 475                              |
| Part                  | 496                                   | 492                               | 491                              |
| Ridor                 | 491                                   | 487                               | 490                              |
| SMO                   | 498                                   | 488                               | 496                              |
| VFI                   | 471                                   | 471                               | 469                              |
| ZeroR                 | 500                                   | 500                               | 500                              |
| BFTree                | 486                                   | 487                               | 485                              |

Πίνακας 17 : Εύκολες εικόνες που ταξινομήθηκαν ως εύκολες για τους τρεις δείκτες

| Algorithms            | ERSP<br>Hard<br>Identified<br>as not<br>easy | GFP Hard<br>Identified<br>as not<br>easy | PS Hard<br>Identified<br>as not<br>easy |
|-----------------------|----------------------------------------------|------------------------------------------|-----------------------------------------|
| BayesNet              | 335                                          | 421                                      | 322                                     |
| JRip                  | 470                                          | 484                                      | 476                                     |
| NaiveBayesMultinomial | 387                                          | 305                                      | 355                                     |
| NaiveBayesSimple      | 414                                          | 370                                      | 371                                     |
| DecisionTable         | 455                                          | 463                                      | 459                                     |
| Part                  | 476                                          | 491                                      | 478                                     |
| Ridor                 | 468                                          | 487                                      | 468                                     |
| SMO                   | 485                                          | 492                                      | 479                                     |
| VFI                   | 465                                          | 463                                      | 452                                     |
| ZeroR                 | 0                                            | 0                                        | 0                                       |
| BFTree                | 487                                          | 484                                      | 480                                     |

Πίνακας 18 : Δύσκολες εικόνες που ταξινομήθηκαν ως μη εύκολες για τους τρεις δείκτες

| Algorithms            | ERSP<br>Sensitivity | GFP<br>Sensitivity | PS<br>Sensitivity |
|-----------------------|---------------------|--------------------|-------------------|
| BayesNet              | 82,0%               | 96,0%              | 62,0%             |
| JRip                  | 98,2%               | 98,2%              | 96,4%             |
| NaiveBayesMultinomial | 79,0%               | 100,0%             | 67,0%             |
| NaiveBayesSimple      | 82,0%               | 98,0%              | 67,8%             |
| DecisionTable         | 95,2%               | 94,2%              | 95,0%             |
| Part                  | 99,2%               | 98,4%              | 98,2%             |
| Ridor                 | 98,2%               | 97,4%              | 98,0%             |
| SMO                   | 99,6%               | 97,6%              | 99,2%             |
| VFI                   | 94,2%               | 94,2%              | 93,8%             |
| ZeroR                 | 100,0%              | 100,0%             | 100,0%            |
| BFTree                | 97,2%               | 97,4%              | 97,0%             |


Πίνακας 19 : Δείκτης Sencitivity για τους τρεις δείκτες

| Algorithms            | ERSP<br>Specifity | GFP<br>Specifity | PS<br>Specifity |
|-----------------------|-------------------|------------------|-----------------|
| BayesNet              | 67,0%             | 84,2%            | 64,4%           |
| JRip                  | 94,0%             | 96,8%            | 95,2%           |
| NaiveBayesMultinomial | 77,4%             | 61,0%            | 71,0%           |
| NaiveBayesSimple      | 82,8%             | 74,0%            | 74,2%           |
| DecisionTable         | 91,0%             | 92,6%            | 91,8%           |
| Part                  | 95,2%             | 98,2%            | 95,6%           |
| Ridor                 | 93,6%             | 97,4%            | 93,6%           |
| SMO                   | 97,0%             | 98,4%            | 95,8%           |
| VFI                   | 93,0%             | 92,6%            | 90,4%           |
| ZeroR                 | 0,0%              | 0,0%             | 0,0%            |
| BFTree                | 97,4%             | 96,8%            | 96,0%           |


Πίνακας 20 : Δείκτης Specificity για τους τρεις δείκτες




Εικόνα 64: Εύκολες εικόνες που ταξινομήθηκαν ως εύκολες για τους τρεις δείκτες



Εικόνα 65: Δύσκολες εικόνες που ταξινομήθηκαν ως μη εύκολες για τους τρεις δείκτες



Εικόνα 66: Δείκτης Sencitivity για τους τρεις δείκτες



Εικόνα 67: Δείκτης Specificity για τους τρεις δείκτες

### 6.3.7 Εξαγωγή καλύτερου μοντέλου πρόβλεψης

Στην παρούσα παράγραφο βελτιώνουμε το μαθηματικό μοντέλο στο οποίο καταλήξαμε στην προηγούμενη παράγραφο. Η βελτίωση γίνεται με βάση τα

αποτελέσματα που εξάγαμε στις προηγούμενες παραγράφους και εφαρμόζοντας δύο επιπλέον τεχνικές.

Σύμφωνα με την πρώτη τεχνική, κάνουμε ανάλυση διακύμανσης με τη μέθοδο μικτής ANOVA, όπως περιγράψαμε στην παράγραφο 4.4, έτσι ώστε να εξετάσουμε αν οι δείκτες παρουσιάζουν διαφορές ως προς την ποιότητα της προβλεψιμότητας.

Στη συνέχεια εφαρμόζουμε μια τεχνική μέσω του λογισμικού εξόρυξης γνώσης WEKA μέσω της οποίας λαμβάνουμε την καλύτερη ομάδα ηλεκτροδίων, τα οποία μας δίνουν βελτιωμένες τιμές πρόβλεψης της δυσκολίας.

### **Ανάλυση διακύμανσης**

Για να καταλήξουμε στο μοντέλο το οποίο είναι ικανό να χρησιμοποιηθεί, προκειμένου να είναι δυνατή η πρόβλεψη της δυσκολίας που συναντά ένα υποκείμενο κατά τη διάρκεια μιας εκπαιδευτικής διαδικασίας, θα εκτελέσουμε στατιστική ανάλυση με το μοντέλο μικτής ANOVA, που περιγράψαμε στο 4.4.

Το γκρουπ το οποίο θα εξετάσουμε είναι τα 14 άτομα που έδωσαν τα ηλεκτροεγκεφαλογραφήματα και θεωρούμε ως εκπαίδευση Α τη διαδικασία αναγνώρισης της εύκολης εικόνας και ως εκπαιδευτικό πρόγραμμα Β τη διαδικασία αναγνώρισης της δύσκολης εικόνας. Οι πληθυσμοί τους οποίους θα μελετήσουμε είναι οι τιμές που έχουν προκύψει για την προβλεπτική ικανότητα των τριών δεικτών μας. Είναι τα δεδομένα του Πίνακα 14, τα οποία είναι τα αποτελέσματα σωστής ταξινόμησης όλων των δεικτών ανά αλγόριθμο :

| Μέθοδοι |      |     |
|---------|------|-----|
| GFP     | ERSP | PS  |
| 901     | 745  | 632 |
| 975     | 961  | 958 |
| 805     | 782  | 690 |
| 860     | 824  | 710 |
| 934     | 931  | 934 |
| 983     | 972  | 969 |
| 974     | 959  | 958 |
| 980     | 983  | 975 |
| 934     | 936  | 921 |
| 500     | 500  | 500 |
| 971     | 973  | 965 |

*Πίνακας 21 : Αποτελέσματα σωστής ταξινόμησης όλων των δεικτών ανά αλγόριθμο που χρησιμοποιήθηκαν στη διαδικασία ανάλυσης διακύμανσης*

Στόχος μας είναι να εξετάσουμε αν οι δείκτες παρουσιάζουν διαφορές ως προς την ποιότητα της προβλεψιμότητας.

Η μηδενική μας υπόθεση είναι ότι οι τρεις δείκτες έχουν περίπου την ίδια στατιστική διαφορά ανάμεσά τους. Αυτό σημαίνει ότι, αν ισχύει η μηδενική υπόθεση και οι τρεις δείκτες μπορούν να εκφράσουν αυτό που μετρούν, δηλαδή την πρόβλεψη της δυσκολίας που συναντά ένα άτομο εκτελώντας τις εκπαιδευτικές διαδικασίες Α και Β. Δηλαδή, ελέγχουμε, εαν τα συγκεκριμένα τρία σετ δεδομένων (προβλεπτική ικανότητα των τριων δεικτών) υποστηρίζουν (ή όχι – αν απορριφθεί η μηδενική πρόταση) ότι είναι δυνατή η πρόβλεψη της διαφορετικότητας των δύο εκπαιδευτικών διαδικασιών. Άρα, κατ' επέκταση, οι δείκτες τους οποίους μελετάμε είναι αποτελεσματικοί. Με επίπεδο σημαντικότητας 5%, θα κάνουμε τον έλεγχο της μηδενικής υπόθεσης :

Η μηδενική μας υπόθεση είναι :

$$H_0: \mu_1 = \mu_2 = \mu_3,$$

έναντι της εναλλακτικής :

$$H_1 : \mu_i \neq \mu_j, \text{ για ένα τουλάχιστον ζευγάρι } (i, j), i, j = 1,2,3$$

Πρέπει να διευκρινίσουμε ότι οι υπολογισμοί έγιναν από τις συμπτυγμένες σχέσεις και με τη βοήθεια του στατιστικού πακέτου SPSS[160].

Εφαρμόζοντας τη διαδικασία και τις εξισώσεις που περιγράψαμε στην παράγραφο 4.4, και με τη βοήθεια του στατιστικού πακέτου SPSS, υπολογίσαμε τον πίνακα Διαχείρισης Μεταχείρισης (Πίνακας 22)

| Ομάδες  | Πλήθος | Άθροισμα | Μέσος όρος | Διακύμανση |
|---------|--------|----------|------------|------------|
| Στήλη 1 | 11     | 9817     | 892,4545   | 20174,27   |
| Στήλη 2 | 11     | 9566     | 869,6364   | 22044,45   |
| Στήλη 3 | 11     | 9212     | 837,4545   | 29192,87   |

Πίνακας 22 : Πίνακας Διαχείρισης Μεταχείρισης

καθώς και τον πίνακα Ανάλυσης Διακύμανσης Διασποράς (Πίνακας 23).

| ΑΝΑΛΥΣΗ ΔΙΑΚΥΜΑΝΣΗΣ   |          |                   |          |          |          |            |
|-----------------------|----------|-------------------|----------|----------|----------|------------|
| Προέλευση διακύμανσης | SS       | βαθμοί ελευθερίας | MS       | F        | τιμή-P   | κριτήριο F |
| Μεταξύ ομάδων         | 16798,24 | 2                 | 8399,121 | 0,352847 | 0,705562 | 3,31583    |
| Μέσα στις ομάδες      | 714116   | 30                | 23803,87 |          |          |            |
| Σύνολο                | 730914,2 | 32                |          |          |          |            |

Πίνακας 23 : Πίνακας Ανάλυσης Διακύμανσης Διασποράς ANOVA

Από τα αποτελέσματα φαίνεται ότι η υπόθεση  $H_0$  είναι τελικά αποδεκτή. Όπως βλέπουμε από τον Πίνακα 23,  $F < F_{\text{κριτήριο}}$ , πράγμα που σημαίνει ότι ισχύει η μηδενική υπόθεση. Συνεπώς, δεν υπάρχει διαφορετικότητα στους μέσους όρους των τριών ομάδων μέτρησης των δεικτών. Άρα δεν υπάρχει και διαχωρισμός της επιρροής των διαφορετικών υποσυνόλων των παραμέτρων πάνω στις παρατηρήσεις των δεικτών πρόβλεψης δυσκολίας. Συνεπώς, οι δείκτες μας επηρεάζονται με παρόμοιο τρόπο από τη διαφορετικότητα των δύο δυσκολιών της εκπαιδευτικής διαδικασίας. Συνεπώς, και οι τρεις δείκτες μας είναι κατάλληλοι για την πρόβλεψη της διαφορετικότητας ως προς τη δυσκολία της εκπαιδευτικής διαδικασίας.



## Βελτίωση προβλεψιμότητας


Στο σημείο αυτό βελτιώνουμε την προβλεψιμότητα των δεικτών, εφαρμόζοντας μια μέθοδο αξιολόγησης της ποιότητάς τους.

Λαμβάνοντας υπόψη τα αποτελέσματα της προηγούμενης παραγράφου και εφόσον και οι τρεις δείκτες μπορούν να χρησιμοποιηθούν το ίδιο καλά, προκειμένου να προβλέψουν τη δυσκολία που έχει κάποιο άτομο κατά τη διάρκεια μιας εκπαιδευτικής διαδικασίας, επιλέγουμε για την περαιτέρω βελτίωση της απόδοσης τον ένα από τους τρεις δείκτες, τον GFP. Στο σημείο αυτό πρέπει να τονίσουμε ότι δοκιμάστηκαν και οι υπόλοιποι δύο δείκτες ως προς τη βελτιστοποίηση και ο εξεταζόμενος σε αυτήν την παράγραφο αλγόριθμος βελτιστοποίησης λειτουργεί εξίσου καλά και στους υπόλοιπους δείκτες.

Διαδοχικά εφαρμόσαμε όλες τις μεθόδους βελτίωσης τις οποίες προσφέρει το λογισμικό εξόρυξης γνώσης WEKA. Υπάρχουν συνολικά 10 αλγόριθμοι βελτίωσης απόδοσης, οι οποίοι μας έδωσαν 10 διαφορετικούς πίνακες. Από τη συγκριτική μελέτη των πινάκων αυτών καταλήξαμε στον αλγόριθμο που δείχνει την καλύτερη βελτιωμένη πρόταση για την προβλεψιμότητα των δεικτών, την οποία και παρουσιάζουμε στη συνέχεια :

Ο αλγόριθμος που μας έδωσε την καλύτερη ομάδα τιμών προβλεψιμότητας για τους δείκτες που στην εργασία μας έδωσαν, με τη σειρά τους, την καλύτερη προβλεψιμότητα της δυσκολίας είναι ο ConsistencySubsetEval.

Έτσι εφαρμόζουμε τον αλγόριθμο ConsistencySubsetEval, ο οποίος υπολογίζει την αξία του κάθε υποσυνόλου καταγραφών των ηλεκτροδίων, λαμβάνοντας υπόψη την προγνωστική του ικανότητα για κάθε καταγραφή μετρήσεων ξεχωριστά μαζί με τον πλεονάζοντα βαθμό ανάμεσα τους.




Εικόνα 68: Οθόνη του WEKA με την εφαρμογή του αλγόριθμου βελτιστοποίησης απόδοσης ConsistencySubsetEval, επάνω στον δείκτη GFP

Το αποτέλεσμα της εφαρμογής του αλγόριθμου φαίνονται στον Πίνακα 24 καθώς και στην Εικόνα 69.


| Αλγόριθμοι            | Correctly classified instances | Incorrectly Classified Instances |
|-----------------------|--------------------------------|----------------------------------|
| BayesNet              | 921                            | 79                               |
| JRip                  | 971                            | 29                               |
| NaiveBayesMultinomial | 805                            | 195                              |
| NaiveBayesSimple      | 860                            | 140                              |
| DecisionTable         | 929                            | 71                               |
| Part                  | 986                            | 14                               |
| Ridor                 | 975                            | 25                               |
| SMO                   | 991                            | 9                                |
| VFI                   | 939                            | 61                               |
| ZeroR                 | 500                            | 500                              |
| BFTree                | 971                            | 29                               |

Πίνακας 24 : Αποτελέσματα σωστής και λανθασμένης ταξινόμησης του δείκτη GFP ανά αλγόριθμο, μετά τη βελτιστοποίηση με τον τον αλγόριθμο ConsistencySubsetEval



Εικόνα 69: Οπτικοποίηση σωστής ταξινόμησης του δείκτη GFP ανά αλγόριθμο, μετά τη βελτιστοποίηση με τον τον αλγόριθμο ConsistencySubsetEval

Κάνοντας μια σύγκριση ανάμεσα στις αποδόσεις των δεικτών, όπως φαίνονται στους πίνακες Πίνακας 5 και Πίνακας 24, παίρνουμε το διάγραμμα της Εικόνα 70.



Εικόνα 70: Διαγραμματική οπτικοποίηση της βελτιωμένης ταξινόμησης ως προς τον δείκτη GFP, μετά τη βελτιστοποίηση με τον τον αλγόριθμο ConsistencySubsetEval

Στην Εικόνα 70 είναι διακριτή η βελτιστοποίηση της ταξινόμησης, δηλαδή της βελτιστοποίησης των σωστών ταξινομήσεων κάποιων αλγορίθμων, όπως ο SMO ο οποίος έχει 991 σωστές ταξινομήσεις και μόνο 9 λανθασμένες (από 980 και 20

που είχε αντίστοιχα), ο Part ο οποίος έχει 986 σωστές ταξινομήσεις και μόνο 14 λανθασμένες (από 983 και 17 που είχε αντίστοιχα),

Άξιο σχολιασμού και παρατήρησης είναι ότι οι Μπαεσιανοί αλγόριθμοι εμφανίζονται αμετάβλητοι, ενώ ο ZeroR δείχνει εντελώς ακατάλληλος και χωρίς να επιδρά καμιά μεταβολή επάνω του. Επίσης ο DecisionTable αλλάζει αρνητικά την πρόβλεψή του.

Θα μπορούσαμε ως τελικό αποτέλεσμα μετά από όλη την ανάλυση που προηγήθηκε στις προηγούμενες παραγράφους να καταλήξουμε ότι για την πρόβλεψη της δυσκολίας που συναντά κάποιο άτομο κατά τη διάρκεια μιας εκπαιδευτικής διαδικασίας, οι καλύτεροι δείκτες για μελέτη και απεικόνιση είναι GFP, ERSP και PS με καλύτερους αλγόριθμους ταξινόμησης τους SMO και Part, και καλύτερο αλγόριθμο βελτιστοποίησης τον ConsistencySubsetEval.

### **6.3.8 Σχολιασμός Αποτελεσμάτων με βάση τα διαγράμματα**

Σημαντικός είναι και ο σχολιασμός που μπορεί να γίνει έχοντας την εικόνα των διαγραμμάτων, ιδιαίτερα αυτών που σχετίζονται με μέσους όρους από όλα τα subjects. Τέτοια διαγράμματα παρήχθησαν κατά τον υπολογισμό του δείκτη Global Field Power.


### **Σχολιασμός διαγραμμάτων Global Field Power (GFP)**

Μελετώντας τα διαγράμματα GFP βρίσκουμε ότι διαφορετικά σημεία του εγκεφάλου δείχνουν να έχουν διαφορετική συμπεριφορά ως προς τη δυσκολία της εκπαιδευτικής διαδικασίας.


Έχοντας υπόψη την Εικόνα 31, όπου φαίνεται η χωρική διάταξη των ηλεκτροδίων, την Εικόνα 32, όπου φαίνεται και η αντίστοιχη ονοματοδοσία,

καθώς και τα παραγόμενα διαγράμματα GFP, όπου βλέπουμε την τάση των ηλεκτροδίων για κάθε ένα από τα tasks (easy και hard recognition) για όλα τα υποκείμενα και για κάθε κανάλι, βγάζουμε τα εξής συμπεράσματα :

Υπάρχει μια γενικότερη τάση να έχουμε υψηλότερα mV (μεγαλύτερη τάση), όταν η δυσκολία του προβλήματος αυξάνει. Για παράδειγμα, να δούμε την Εικόνα 73, την Εικόνα 74 και την Εικόνα 75,




Εικόνα 71: Λοβοί του ανθρώπινου εγκεφάλου  
(public domain image, free to use, share or modify, even commercially)




Εικόνα 72: GFP διαγράμματα για Μετωπιαία (Frontal) Ηλεκτρόδια 1 και 2


## «Ψηφιακή Ανάλυση Ηλεκτροεγκεφαλογραφικού Σήματος (ΗΕΓ) Εφαρμογές στην Εκπαίδευση»



Εικόνα 73: GFP διαγράμματα για Πλευρικά (Parietal) Ηλεκτρόδια 7 και 8



Εικόνα 74: GFP διαγράμματα για Ινιακά (Occipital) Ηλεκτρόδια 9 και 10



Εικόνα 75: GFP διαγράμματα για Κροταφικά (Temporal) Ηλεκτρόδια 13 και 16

όπου μπορούμε εύκολα να διακρίνουμε ότι το κόκκινο σήμα που αντιστοιχεί στη δύσκολη εκπαιδευτική διαδικασία (αναγνώριση δύσκολης εικόνας) ξεχωρίζει εμφανώς από την μπλε εύκολη εκπαιδευτική διαδικασία (αναγνώριση εύκολης


εικόνας). Τα υποκείμενα (subjects), όταν αντιμετωπίζουν εκπαιδευτική διαδικασία μεγαλύτερης δυσκολίας, παράγουν σήματα μεγαλύτερης τάσης.

Στην **Εικόνα 71** μπορεί κανείς να δει τους διάφορους λοβούς του ανθρώπινου εγκεφάλου, οι οποίοι αναφέρονται στην παραπάνω ανάλυση.

Επίσης η μελέτη των κορυφώσεων μπορεί να μας δώσει κάποια σημαντικά συμπεράσματα. Σύμφωνα με αυτά που έχουμε περιγράψει για τις κορυφώσεις στην παράγραφο 4.3.3, και τα διαγράμματα GFP (τα διαγράμματα GFPs έχουν παραχθεί με την ίδια λογική - epoching), μπορούμε να κάνουμε τα εξής σχόλια :

Στα διαγράμματά μας πρέπει να προσέξουμε ότι παρουσιάζεται ολόκληρο το epoch (1000 σημεία - 1000 msec για εύκολη και δύσκολη εκπαιδευτική διαδικασία). Άρα πρέπει να έχουμε υπόψη μας ότι η περιοχή -100 ms έως 0 ms είναι πριν το ερέθισμα, στο 0 έχουμε το ερέθισμα, ενώ η περιοχή 100 ms – 900 ms είναι μετά το ερέθισμα. Άρα η κορυφώσεις εμφανίζονται με ένα offset 100 points. Έτσι για παράδειγμα οι κορυφώσεις P300 εμφανίζονται στο 400 των διαγραμμάτων.


Έτσι λοιπόν, μπορούμε να παρατηρήσουμε τις P200-P300 και N250-N400 στα εμπρόσθια ηλεκτρόδια 11 και 12 της **Εικόνα 76**.



**Εικόνα 76:** GFP διαγράμματα για τα Ηλεκτρόδια 11 και 12 όπου φαίνονται οι κορυφώσεις P200, P300, N250, N400

## Σχολιασμός οπτικοποίησης εγκεφαλικής δραστηριότητας

Ενδιαφέροντα συμπεράσματα επίσης προκύπτουν από τη μελέτη των οπτικοποιήσεων των εικόνων



**Εικόνα 77:** Οπτικοποίηση ηλεκτρικής δραστηριότητας εγκεφάλου που υπόκειται σε μια εύκολη εκπαιδευτική διαδικασία (η χρωματιστή κλίμακα είναι ηλεκτρική δραστηριότητα σε mV)


Εικόνα 77, Εικόνα 78, οι οποίες αποτελούν στην ουσία οπτικοποιήσεις της εγκεφαλικής ηλεκτρικής δραστηριότητας.



Η οπτικοποίηση αφορά δεδομένα που χρησιμοποιήθηκαν στην παρούσα διατριβή και πιο συγκεκριμένα ανήκουν σε ένα από τα άτομα που υποβλήθηκαν στη διαδικασία αναγνώρισης ενός ζώου μέσα από διάφορες εικόνες. Παρουσιάζουμε ενδεικτικά 2 τέτοιες εικόνες. Στην

*Εικόνα 77* έχουμε τέσσερα στιγμιότυπα από τέσσερις χρονικές στιγμές μιας εποχής μιας εύκολης εκπαιδευτικής δραστηριότητας. Η χρονική στιγμή 100 ms είναι στην περίοδο πριν το ερέθισμα, όπου ο φλοιός του εγκεφάλου βρίσκεται σε χαμηλή ηλεκτρική δραστηριότητα και ουσιαστικά το υποκείμενο βρίσκεται σε κατάσταση αναμονής. Βλέπουμε ότι ακόμα και στα 100ms μετά το ερέθισμα, ο εγκέφαλος του υποκειμένου δεν έχει αντιληφθεί ακόμα την εικόνα. Πάρα πολύ χαρακτηριστικό είναι ότι στα 300ms, όπου προηγουμένως είδαμε και το P300, έχουμε έντονη ηλεκτρική δραστηριότητα, ενώ κατά το τέλος της εποχής έχουμε και πάλι πολύ χαμηλά δυναμικά στον εγκεφαλικό φλοιό.

Αντίστοιχες εικόνες, αλλά με εμφανώς μεγαλύτερα ηλεκτρικά δυναμικά, παρατηρούμε στην *Εικόνα 78*. Εδώ μπορούμε να διακρίνουμε αντίστοιχες καταστάσεις σχετικής ηρεμίας της εγκεφαλικής δραστηριότητας, τόσο στην περίοδο πριν το ερέθισμα (100ms), όσο και στην αμέσως μετά το ερέθισμα περίοδο (100ms). Εύκολα όμως διακρίνουμε και την κατάσταση εγρήγορσης, στα 300ms αλλά και τη φάση της πτώσης της ηλεκτρικής δραστηριότητας στο τέλος της εποχής (800ms).



**Εικόνα 78:** Οπτικοποίηση ηλεκτρικής δραστηριότητας εγκεφάλου που υπόκειται σε μια δύσκολη εκπαιδευτική διαδικασία (η χρωματιστή κλίμακα είναι ηλεκτρική δραστηριότητα σε mV)


Πολύ εύκολα διακριτή είναι η χρωματική διαφορά ανάμεσα στην

Εικόνα 77 και την Εικόνα 78, όπου είναι εμφανές ότι το υποκείμενο βιώνει πιο έντονα τη δύσκολη εκπαιδευτική διαδικασία, ακόμα και στη φάση της υποτιθέμενης ηρεμίας ανάμεσα στα ερεθίσματα (στιγμές -100ms και 800ms). Επίσης όμως είναι και πολύ πιο έντονα τα αναπτυσσόμενα δυναμικά και στο P300, όταν το υποκείμενο αντιμετωπίζει τη δύσκολη εκπαιδευτική διαδικασία.

Μια πολύ σημαντική παρατήρηση που κάνουμε στις δύο προαναφερόμενες εικόνες είναι το γεγονός ότι πιο έντονα χρωματισμένες περιοχές της εγκεφαλικής δραστηριότητας είναι οι μετωπιαίες, οι οποίες, σύμφωνα και με τη

θεωρία, αναμέναμε να είναι πραγματικά πιο έντονες, αφού ο μετωπιαίος λοβός είναι αυτός που συμμετέχει πιο ενεργά σε μια διαδικασία μάθησης και εκπαίδευσης.

Τέλος, στην εικόνα *Εικόνα 79* διακρίνουμε την εντονότερη ηλεκτρική δραστηριότητα του εγκεφαλικού φλοιού κατά τη διάρκεια της δύσκολης εκπαιδευτικής διαδικασίας (αριστερά) από την εύκολη (δεξιά) κατά την ίδια χρονική στιγμή (300ms), όπου έχουμε και την αντίδραση του εγκεφάλου στο ερέθισμα.



**Εικόνα 79:** Οπτικοποίηση ηλεκτρικής δραστηριότητας εγκεφάλου που υπόκειται σε μια δύσκολη (αριστερά) και μια εύκολη (δεξιά) εκπαιδευτική διαδικασία 300ms μετά το ερέθισμα

### 6.3.9 Αφαίρεση της Επίδρασης των Προκλητών Δυναμικών

Στη συνέχεια της έρευνάς μας προχωρήσαμε ακόμα ένα βήμα. Αφαιρέσαμε αλγοριθμικά την επίδραση των προκλητών δυναμικών, με αποτέλεσμα να προκύψει ένα σήμα το οποίο προσιδιάζε σε απλό ηλεκτροεγκεφαλογράφημα. Η μέθοδος αφαίρεσης της επίδρασης των προκλητών δυναμικών ξεκίνησε με μια διαδικασία προεπεξεργασίας και ανάλυσης του σήματος.

Αρχικά λοιπόν επεξεργαστήκαμε το σήμα, ώστε να αφαιρέσουμε τα προκλητά δυναμικά. Στην αρχική του κατάσταση το σήμα χωρίζεται σε 100 εποχές (epochs), καθεμιά από τις οποίες περιλαμβάνει 100 γεγονότα (events) των 1000 σημείων περίπου. Με τη μέθοδο που περιγράφουμε ακριβώς παρακάτω αφαιρούμε την επίδραση των προκλητών δυναμικών.

Βρήκαμε ότι η εποχή με τα λιγότερα σημεία περιείχε 974 σημεία. Αυτήν την εποχή χρησιμοποιήσαμε ως βάση για τη φάση της προεπεξεργασίας. Στη φάση αυτή, το πραγματικό ηλεκτροεγκεφαλικό σήμα απομονώθηκε από τα δεδομένα των προκλητών δυναμικών (Brain Evoked Potential Data - BEPD). Η διαδικασία που ακολουθήσαμε, προκειμένου να απομονώσουμε αυτά τα δεδομένα, ήταν η παρακάτω :

1. Το σήμα BEPD χωρίστηκε σε  $k$  τμήματα σύμφωνα με τα 100 γεγονότα (events) που είχαμε.
2. Χρησιμοποιήσαμε ως πρότυπο (pattern) το μικρότερο σε μήκος τμήμα ανάμεσα σε δύο γεγονότα και απομονώσαμε  $n$  ίσα τμήματα του BEPD.
3. Αφαιρέσαμε τα πρώτα 74 σημεία τα οποία περιείχαν το ερέθισμα και έτσι έμειναν 900 σημεία για κάθε τμήμα.
4. Στη συνέχεια κάθε τμήμα υπέστη μετασχηματισμό FFT και από αυτό υπολογίσαμε την εικόνα και τα πραγματικά μέρη.
5. Έπειτα τα  $n$  ίσα BEPDs υπέστησαν τη διαδικασία averaging και έτσι προέκυψε τελικά ένα BEPD το οποίο ήταν και ο μέσος όρος των υπολοίπων.
6. Το averaged τμήμα BEPD υπέστη μετασχηματισμό FFT και από αυτό εξήχθη η πραγματική εικόνα και τα μέρη του.
7. Υπολογίσαμε τη διαφορά ανάμεσα στα αρχικά BEPDs και το averaged BEPD (real and image parts).
8. Έτσι προέκυψε το τελικό EEG για κάθε τμήμα το οποίο ήταν απαλλαγμένο από το προκλητό δυναμικό.

Τα αποτελέσματα που πήραμε για τους δείκτες ήταν τα εξής :

Στον **Πίνακα 25** φαίνονται τα αποτελέσματα από την εξαγωγή του δείκτη GFP μετά την επεξεργασία τους με τους διάφορους αλγόριθμους του WEKA.

| Αλγόριθμοι            | Correctly<br>classified<br>instances | Incorrectly<br>Classified<br>Instances | root<br>mean<br>squared<br>error | TP rates<br>Weighted<br>Avg. | FP rates<br>Weighted<br>Avg. |
|-----------------------|--------------------------------------|----------------------------------------|----------------------------------|------------------------------|------------------------------|
| BayesNet              | 844                                  | 56                                     | 0,2291                           | 93,8%                        | 6,2%                         |
| JRip                  | 884                                  | 16                                     | 0,1307                           | 98,2%                        | 1,8%                         |
| NaiveBayesMultinomial | 669                                  | 231                                    | 0,4928                           | 74,3%                        | 25,7%                        |
| NaiveBayesSimple      | 792                                  | 108                                    | 0,325                            | 88,0%                        | 12,0%                        |
| DecisionTable         | 872                                  | 28                                     | 0,1624                           | 96,9%                        | 3,1%                         |
| Part                  | 885                                  | 15                                     | 0,1291                           | 98,3%                        | 1,7%                         |
| Ridor                 | 878                                  | 22                                     | 0,1563                           | 97,6%                        | 2,4%                         |
| SMO                   | 893                                  | 7                                      | 0,0882                           | 99,2%                        | 0,8%                         |
| VFI                   | 816                                  | 84                                     | 0,3499                           | 90,7%                        | 9,3%                         |
| ZeroR                 | 450                                  | 450                                    | 0,5                              | 50,0%                        | 50,0%                        |
| BFTree                | 882                                  | 18                                     | 0,137                            | 98,0%                        | 2,0%                         |

Πίνακας 25 : Αποτελέσματα ταξινόμησης δεδομένων με δείκτη GFP μετά τη αφαίρεση της επίδρασης των προκλητών δυναμικών


Από τον πίνακα βλέπουμε ότι παράγονται πολύ καλές κατηγοριοποιήσεις, όπως SMO 99,2%, PART 98,3%, JRip 98,2%, BFTree 98,0%, Ridor 97,4%. Επίσης στον Πίνακα 26, αναφέρονται οι χρόνοι δημιουργίας του μοντέλου, όπου και πάλι έχουμε για το SMO πολύ καλό χρόνο, μόλις 0,05ms.

Ανάλογα με το ποσοστό ορθής πρόβλεψης της δυσκολίας, καλύτερος κατηγοριοποιητής αναδεικνύεται ο SMO, με ποσοστό ορθών προβλέψεων δυσκολίας στο 99,2%, και με το μικρότερο χρόνο παραγωγής του μοντέλου (πίνακας 2) στα 50 msec. Ισάξιος ταξινομητής του SMO αναδεικνύεται ο αλγόριθμος PART, με ποσοστό ορθών προβλέψεων δυσκολίας στο 98,3% αλλά με μεγαλύτερο χρόνο παραγωγής του μοντέλου στα 60 msec. Στην εικόνα 5 παρουσιάζουμε όλο το αποτέλεσμα της ταξινόμησης με τον SMO ("Stratified cross-validation" classification summary).


| Αλγόριθμοι            | Time taken to build model |
|-----------------------|---------------------------|
| BayesNet              | 0,03                      |
| JRip                  | 0,10                      |
| NaiveBayesMultinomial | 0,00                      |
| NaiveBayesSimple      | 0,00                      |
| DecisionTable         | 0,26                      |
| Part                  | 0,06                      |
| Ridor                 | 0,11                      |
| SMO                   | 0,05                      |
| VFI                   | 0,26                      |
| ZeroR                 | 0,00                      |
| BFTree                | 0,63                      |

Πίνακας 26 : Χρόνος δημιουργίας μοντέλου δεδομένων με δείκτη GFP μετά τη αφαίρεση της επίδρασης των προκλητών δυναμικών


Επίσης στις εικόνες *Εικόνα 80*, *Εικόνα 81* και *Εικόνα 82* βλέπουμε μια αναπαράσταση με ραβδογράμματα των αποτελεσμάτων που παρουσιάζονται και στους πίνακες *Πίνακας 25* και *Πίνακας 26*. Πιο συγκεκριμένα, στην *Εικόνα 80* βλέπουμε την ικανότητα πρόβλεψης των ταξινομητών που χρησιμοποιήσαμε, στην *Εικόνα 81* βλέπουμε το μέσο τετραγωνικό σφάλμα καθενός ταξινομητή,



**Εικόνα 80:** Ικανότητα ορθής πρόβλεψης ταξινομητών για δεδομένα με δείκτη GFP μετά την αφαίρεση της επίδρασης των προκλητών δυναμικών



**Εικόνα 81:** Μέσο τετραγωνικό σφάλμα ταξινομητών για δεδομένα με δείκτη GFP μετά την αφαίρεση της επίδρασης των προκλητών δυναμικών



**Εικόνα 82:** Χρόνος δημιουργίας μοντέλου για δεδομένα με δείκτη GFP μετά την αφαίρεση της επίδρασης των προκλητών δυναμικών

|                                         |           |                         |           |        |           |          |                     |
|-----------------------------------------|-----------|-------------------------|-----------|--------|-----------|----------|---------------------|
| Time taken to build model: 0.03 seconds |           |                         |           |        |           |          |                     |
| === Stratified cross-validation ===     |           |                         |           |        |           |          |                     |
| === Summary ===                         |           |                         |           |        |           |          |                     |
| Correctly Classified Instances          | 893       | 99.2222 %               |           |        |           |          |                     |
| Incorrectly Classified Instances        | 7         | 0.7778 %                |           |        |           |          |                     |
| Kappa statistic                         | 0.9844    |                         |           |        |           |          |                     |
| Mean absolute error                     | 0.0078    |                         |           |        |           |          |                     |
| Root mean squared error                 | 0.0882    |                         |           |        |           |          |                     |
| Relative absolute error                 | 1.5556 %  |                         |           |        |           |          |                     |
| Root relative squared error             | 17.6383 % |                         |           |        |           |          |                     |
| Total Number of Instances               | 900       |                         |           |        |           |          |                     |
| === Detailed Accuracy By Class ===      |           |                         |           |        |           |          |                     |
|                                         | TP Rate   | FP Rate                 | Precision | Recall | F-Measure | ROC Area | Class               |
|                                         | 0.993     | 0.009                   | 0.991     | 0.993  | 0.992     | 0.992    | Easy_GFPs_1_SUBJECT |
|                                         | 0.991     | 0.007                   | 0.993     | 0.991  | 0.992     | 0.992    | Hard_GFPs_1_SUBJECT |
| Weighted Avg.                           | 0.992     | 0.008                   | 0.992     | 0.992  | 0.992     | 0.992    |                     |
| === Confusion Matrix ===                |           |                         |           |        |           |          |                     |
| a                                       | b         | <-- classified as       |           |        |           |          |                     |
| 447                                     | 3         | a = Easy_GFPs_1_SUBJECT |           |        |           |          |                     |
| 4                                       | 446       | b = Hard_GFPs_1_SUBJECT |           |        |           |          |                     |

**Εικόνα 83:** Stratified cross-validation classification summary μετά τη αφαίρεση της επίδρασης των προκλητών δυναμικών

ενώ στην *Εικόνα 82* βλέπουμε τους χρόνους που χρειάστηκε το υπολογιστικό σύστημα, για να παράξει τα μοντέλα.

Αντίστοιχα οι πίνακες για τους δείκτες sensitivity και specificity έχουν ως εξής :

Sensitivity και Specificity για τον δείκτη GFP μετά την αφαίρεση των προκλητών δυναμικών

Η Sensitivity και η Specificity για τον δείκτη GFP φαίνεται στον *Πίνακας 27*. Τα αποτελέσματα προκύπτουν από την εφαρμογή των τιμών που πήραμε κατά τον υπολογισμό του δείκτη GFP στις εξισώσεις (42) και (43).



| Algorithms            | Easy Identified as easy | Hard Identified as not easy | Sensitivity | Specificity | Instances |
|-----------------------|-------------------------|-----------------------------|-------------|-------------|-----------|
| BayesNet              | 427                     | 417                         | 47,4%       | 46,3%       | 900       |
| JRip                  | 439                     | 445                         | 48,8%       | 49,4%       | 900       |
| NaiveBayesMultinomial | 450                     | 219                         | 50,0%       | 24,3%       | 900       |
| NaiveBayesSimple      | 436                     | 356                         | 48,4%       | 39,6%       | 900       |
| DecisionTable         | 439                     | 433                         | 48,8%       | 48,1%       | 900       |
| Part                  | 440                     | 445                         | 48,9%       | 49,4%       | 900       |
| Ridor                 | 435                     | 443                         | 48,3%       | 49,2%       | 900       |
| SMO                   | 447                     | 446                         | 49,7%       | 49,6%       | 900       |
| VFI                   | 442                     | 374                         | 49,1%       | 41,6%       | 900       |
| ZeroR                 | 450                     | 0                           | 50,0%       | 0,0%        | 900       |
| BFTree                | 438                     | 444                         | 48,7%       | 49,3%       | 900       |


*Πίνακας 27 : Sensitivity και Specifity δεδομένων με δείκτη GFP μετά την αφαίρεση της επίδρασης των προκλητών δυναμικών*

Μπορούμε να κάνουμε μια σύγκριση ανάμεσα στους πίνακες Πίνακας 5, Πίνακας 6 και Πίνακας 7, τους οποίους εξάγαμε στην παράγραφο 6.3.2, όπου τα ποσοστά φαίνεται να είναι ελαφρώς διαφοροποιημένα προς το καλύτερο για κάποιους δείκτες. Αυτό σημαίνει ότι με την αφαίρεση των προκλητών δυναμικών κάποιοι δείκτες δείχνουν να βελτιώνονται ελαφρά και κάποιοι άλλοι αρκετά περισσότερο. Για παράδειγμα, ο καλύτερός μας αλγόριθμος (SMO) φτάνει στο 99,2% προβλεπτικής ικανότητας, ενώ αρκετά βλετιωμένοι δείχνουν να είναι και οι BayesNet, DecisionTable, JRI και BFTree. Αντίθετα ο Part που είναι ο δεύτερος σε προβλεψιμότητα αλγόριθμός μας δε δείχνει να βελτιώνεται καθόλου, αλλά ούτε και να χάνει την ικανότητα πρόβλεψης.

Στον Πίνακας 28 , καθώς και στην Εικόνα 84, παραθέτουμε τις διαφορές ως προς την προβλεψιμότητα ανάμεσα στα αποτελέσματα των πινάκων Πίνακας 5 και Πίνακας 25.

| Αλγόριθμοι            | TP rates Weighted Avg. with Evoked | TP rates Weighted Avg. without Evoked |
|-----------------------|------------------------------------|---------------------------------------|
| BayesNet              | 90,10%                             | 93,80%                                |
| JRip                  | 97,50%                             | 98,20%                                |
| NaiveBayesMultinomial | 80,50%                             | 74,30%                                |
| NaiveBayesSimple      | 86,00%                             | 88,00%                                |
| DecisionTable         | 93,40%                             | 96,90%                                |
| Part                  | 98,30%                             | 98,30%                                |
| Ridor                 | 97,40%                             | 97,60%                                |
| SMO                   | 98,00%                             | 99,20%                                |
| VFI                   | 93,40%                             | 90,70%                                |
| ZeroR                 | 50,00%                             | 50,00%                                |
| BFTree                | 97,10%                             | 98,00%                                |

Πίνακας 28 : Διαφορές ως προς το ποσοστό ορθών προβλέψεων των μοντέλων, ως προς τον δείκτη GFP πριν και μετά την αφαίρεση των προκλητών δυναμικών




Εικόνα 84: Διαγραμματική οπτικοποίηση της βελτιωμένης ταξινόμησης ως προς τον δείκτη GFP, πριν και μετά την αφαίρεση των προκλητών δυναμικών

Παρατηρούμε επίσης ότι ο δείκτης NaiveBayesMultinomial, χάνει αρκετή ικανότητα προβλεψιμότητας, ενώ χαμένος βγαίνει επίσης και ο VFI.

Τέλος, μπορούμε να κάνουμε και μια τριπλή συγκριτική απεικόνιση της δυνατότητας πρόβλεψης των αλγοριθμικών μοντέλων που εξετάζουμε ως προς τον δείκτη GFP, σύμφωνα με τη μέθοδο βελτίωσης με την επιλογή των καλύτερων ηλεκτροδίων που μας έδωσε ο αλγόριθμος ConsistencySubsetEval (Εικόνα 70) και τη μέθοδο βελτίωσης που πήραμε στην παρούσα παράγραφο. Τα αποτελέσματα φαίνονται στον Πίνακας 29, καθώς και στην Εικόνα 85.

| Αλγόριθμοι            | TP rates Weighted Avg. with Evoked | TP rates Weighted Avg. without Evoked | TP rates Weighted Avg. with ConsistencySubsetEval |
|-----------------------|------------------------------------|---------------------------------------|---------------------------------------------------|
| BayesNet              | 90,10%                             | 93,80%                                | 90,10%                                            |
| JRip                  | 97,50%                             | 98,20%                                | 97,50%                                            |
| NaiveBayesMultinomial | 80,50%                             | 74,30%                                | 80,50%                                            |
| NaiveBayesSimple      | 86,00%                             | 88,00%                                | 86,00%                                            |
| DecisionTable         | 93,40%                             | 96,90%                                | 93,40%                                            |
| Part                  | 98,30%                             | 98,30%                                | 98,30%                                            |
| Ridor                 | 97,40%                             | 97,60%                                | 97,40%                                            |
| SMO                   | 98,00%                             | 99,20%                                | 98,00%                                            |
| VFI                   | 93,40%                             | 90,70%                                | 93,40%                                            |
| ZeroR                 | 50,00%                             | 50,00%                                | 50,00%                                            |
| BFTree                | 97,10%                             | 98,00%                                | 97,10%                                            |

Πίνακας 29 : Συγκριτικός πίνακας ανάμεσα στις δύο μεθόδους βελτιστοποίησης πρόβλεψης του δείκτη GFP, πριν την αφαίρεση των προκλητών δυναμικών, μετά την αφαίρεση των προκλητών δυναμικών και μετά την εφαρμογή του αλγόριθμου ConsistencySubsetEval



Εικόνα 85: Συγκριτική διαγραμματική οπτικοποίηση της βελτιωμένης ταξινόμησης ως προς τον δείκτη GFP, πριν την αφαίρεση των προκλητών δυναμικών, μετά την εφαρμογή του αλγόριθμου ConsistencySubsetEval και μετά την αφαίρεση των προκλητών δυναμικών

#### 6.4 Συμπεράσματα και μελλοντική έρευνα

Σε ό,τι αφορά την ανίχνευση σταθερών σημείων και στάσιμων κυμάτων σε EEGs, σύμφωνα με αυτά που καταγράφονται στην παράγραφο 6.1, συμπεραίνουμε ότι σταθερά σημεία παρουσιάζονται με σαφήνεια στα σημεία τομής των πολωνύμων παρεμβολής (Εικόνα 42, Εικόνα 43). Αυτά τα ευρήματα είναι συνεπή με τη τη θεωρία που περιγράφεται στη βιβλιογραφία. Επιπλέον, στην παρούσα διδακτορική διατριβή, παρουσιάσαμε μεθόδους εξόρυξης δεδομένων με τη βοήθεια χρονοσειρών με χρήση συντελεστών αυτοσυσχέτισης και χαρακτηριστικών συμμετρίας ηλεκτροεγκεφαλογραφικών χρονοσειρών. Εφαρμόσαμε μια επαναλαμβανόμενη διαδικασία αυτοσυσχέτισης σε πραγματικά ηλεκτροεγκεφαλογραφικά χρονολογικά στοιχεία, σε μια προσπάθεια να διερευνήσουμε πειραματικά και να βρούμε μια σχέση διασύνδεσης μεταξύ των δεδομένων των χρονοσειρών και κρυφών πληροφοριών που σχετίζονται με τις ιδιότητες σταθερών τμημάτων χρονοσειρών. Τα αποτελέσματα που βρήκαμε δείχνουν ότι ο προτεινόμενος αλγόριθμος μπορεί να παρέχει τη βέλτιστη ανάλυση χρόνου-συχνότητας, χρησιμοποιώντας τη μέθοδο αυτοσυσχέτισης, προκειμένου να τονίσει σταθερά

σημεία σε τμήματα ενός EEG γύρω από μια περιοχή εμπιστοσύνης. Αν και είναι γενικά αποδεκτό ότι τα σήματα EEG δεν είναι στάσιμα, αποδείξαμε ότι μπορούμε να απομονώσουμε σημεία, τα οποία είναι σταθερά και στα οποία μπορούμε να διακρίνουμε στασιμότητα. Τα αποτελέσματα που βρήκαμε είναι σε συμφωνία με τις προτεινόμενες από τη βιβλιογραφία μεθόδους εξαγωγής συμπερασμάτων σχετικά με την προβεψιμότητα χαρακτηριστικών χρονολογικών σειρών. Έτσι και η συγκεκριμένη μεθοδολογία μπορεί να χρησιμοποιηθεί σε διαδικασίες πρόβλεψης και αναγνώρισης δυσκολιών κατά τη διάρκεια εκπαιδευτικών διεργασιών που υπόκεινται τα άτομα από τα οποία λαμβάνονται τα ηλεκτροεγκεφαλογραφήματα.

Ως μελλοντική εργασία επάνω στην ανίχνευση σταθερών σημείων προτείνουμε :

- την περαιτέρω μελέτη της μεθόδου, εκτελώντας περισσότερα πειράματα με μεγαλύτερη ποικιλία ηλεκτροεγκεφαλογραφικών δεδομένων. Η πραγματοποίηση εκτεταμένων πειραμάτων θα βοηθήσει να ληφθούν στατιστικά σημαντικά αποτελέσματα και, ως εκ τούτου, να ελεγχθούν και να επαληθευτούν υποθέσεις σε ένα σύνολο πραγματικών και διαφορετικών δεδομένων.
- την κυματιδιακή αναγνώριση προτύπων, προκειμένου να δημιουργήσουμε την προσωπική κυματιδιακή ταυτότητα εκπαίδευσης ενός ατόμου.

Σε ό,τι αφορά τη μέτρηση συγχρονισμού :

Στην έρευνα αυτή αναπτύξαμε μια νέα μέθοδο μέτρησης συγχρονισμού μικρής ομάδας δεδομένων, χρησιμοποιώντας μια νέα τεχνική. Σύμφωνα με αυτήν την τεχνική, δημιουργήσαμε πρότυπες κυματομορφές και πολυώνυμα παρεμβολής. Στη συνέχεια, με μια διαδικασία παλινδρόμησης και μεταβολής της φάσης τμημάτων του EEG συγχρονίσαμε το πρότυπο με τα τμήματα αυτά. Η γραφική απεικόνιση της διαδικασίας αποκάλυψε στάσιμα σημεία. Ο συγχρονισμός επιτεύχθηκε μετά από αλληπάλληλα πειράματα και μεταβολές στον αριθμό των

τμημάτων και στον αριθμό των σημείων του σήματος καθώς και στους βαθμούς ελευθερίας των πολωνύμων.

Η εργασία μας βασίστηκε καθαρά σε πειραματικά αποτελέσματα. Μια εργασία για τους μελετητές τους θέματος θα είναι να βρεθεί το ακριβές μαθηματικό μοντέλο που θα εξηγεί αυτά τα πειραματικά αποτελέσματα.

Σε ό,τι αφορά την εύρεση μαθηματικών μοντέλων με τη μελέτη νευροφυσιολογικών δεικτών :

Από τα αποτελέσματα που προέκυψαν στην παράγραφο 5.3 και την αξιολόγησή τους με διαγραμματικές τεχνικές και τους δείκτες Sensitivity και Specificity στις παραγράφους 5.4 και 5.3 αντίστοιχα, διαπιστώνουμε ότι με το συνδυασμό των μαθηματικών μοντέλων που χρησιμοποιήσαμε στην παράγραφο 5.3 μπορούμε να προβλέψουμε με πολύ μεγάλη επιτυχία τη δυσκολία που αντιμετωπίζει ένα άτομο κατά τη διάρκεια μιας εκπαιδευτικής διαδικασίας, όπως αυτή της αναγνώρισης εύκολα ή δύσκολα ενός αντικειμένου μέσα σε μια εικόνα. Αυτά που περιγράφουμε στη συγκεκριμένη μελέτη μπορούν να επεκταθούν σε διάφορες άλλες εκπαιδευτικές διαδικασίες, όπου μια κατάσταση ή ένα πρόβλημα είναι πιο δύσκολο από ό,τι ένα άλλο.

Λαμβάνοντας υπόψη τα αποτελέσματα της παρούσας έρευνας και έχοντας τα ηλεκτροεγκεφαλογραφικά σήματα EEG, τα οποία λαμβάνονται κατά τη διάρκεια της εκπαιδευτικής διαδικασίας, μπορούν να εντοπισθούν σημεία όπου κάποιο άτομο αντιμετωπίζει δυσκολίες, όταν κάνει διάφορες εκπαιδευτικές δράσεις.

Στη συγκεκριμένη έρευνα διαμορφώσαμε ένα νέο μαθηματικό μοντέλο, το οποίο βασίστηκε σε κάποιους αλγόριθμους με πολύ καλές προβλέψεις, όπως οι SMO, PART, JRip, Ridor, BFTree. Σε όλους τους παραπάνω αλγόριθμους είχαμε ποσοστά ορθών προβλέψεων πάνω πάνω από το 97%. Εάν από το μοντέλο αφαιρέσουμε κάποιους αλγόριθμους με μεγάλο χρόνο δημιουργίας μοντέλου, όπως τον BFTree, εκτός από ακρίβεια επιτυγχάνουμε και μεγάλη ταχύτητα. Ο

τελευταίος αλγόριθμος έχει μεγάλο χρόνο δημιουργίας μοντέλου, επειδή κατά τη διάρκεια του σχηματισμού του, παράγει δυαδικά δένδρα.

Μπορούμε να εξάγουμε επίσης πολύ ενδιαφέροντα συμπεράσματα από τη χρήση των δύο δεικτών Ευαισθησίας και Ειδικότητας. Μπορούμε να παρατηρήσουμε ότι οι αλγόριθμοι που έδωσαν την καλύτερη διαγραμματική εικόνα είχαν και τα καλύτερα αποτελέσματα βάσει των δεικτών. Για παράδειγμα, ο SMO, ο οποίος ήταν και ο καλύτερος αλγόριθμος, σε συνδυασμό με τη δυνατότητα πρόβλεψης και τον χρόνο δημιουργίας του μοντέλου, είχε και τα καλύτερα αποτελέσματα σχετικά με τους δείκτες που μελετήσαμε. Η ευαισθησία του ήταν 97,6% και η ειδικότητά του είναι 98,4%. Άλλος αλγόριθμος ο οποίος έδωσε πολύ καλά αποτελέσματα πρόβλεψης ήταν ο PART με μικρό χρόνο δημιουργίας μοντέλου και τους δείκτες ευαισθησίας 98,4% και ειδικότητας 98,2%.

Σε αντίθεση με τους παραπάνω αλγόριθμους, ορισμένοι άλλοι αλγόριθμοι που δεν εξήγαγαν καλά αποτελέσματα κατά την πρόβλεψη του επιπέδου δυσκολίας της εικόνας, έχουν αρκετά παράξενα αποτελέσματα, όσον αφορά τους δύο δείκτες αξιολόγησης. Για παράδειγμα, ο αλγόριθμος NaiveBayesMultinomial έχει ευαισθησία 100% και ειδικότητα 61%, ενώ ο αλγόριθμος ZeroR έχει Ευαισθησία 100% και Ειδικότητα 0%. Το παραπάνω μας δείχνει ότι για τη συγκεκριμένη κατηγορία προβλημάτων κάποιοι δείκτες είναι πολύ ευαίσθητοι, αλλά καθόλου ειδικοί ή αρκετά ευαίσθητοι αλλά σχετικά κακοί στην εξειδίκευση.

Ένα πολύ σημαντικό επιπλέον συμπέρασμα που καταγράφηκε και στην παράγραφο 6.3.1 και το οποίο αξίζει να επισημάνουμε είναι το γεγονός ότι οι δείκτες έχουν πολύ καλύτερη προβλεπτική αποτελεσματικότητα, όταν αυξάνεται ο αριθμός των ηλεκτροδίων καταγραφής του EEG. Δηλαδή, εάν χρησιμοποιούμε 2, 4, 6 κανάλια, η προβλεπτική ικανότητα των δεικτών είναι πάρα πολύ κακή. Δοκιμάσαμε με αρκετούς διαφορετικούς συνδυασμούς αριθμού καναλιών και καταλήξαμε ότι πρέπει να πάρουμε τον μεγαλύτερο δυνατό αριθμό καταγραφών, άρα τον μεγαλύτερο δυνατό αριθμό ηλεκτροδίων.

Η διαδικασία πρόβλεψης βελτιώθηκε ακόμα πιο πολύ, από τη στιγμή που ζητήσαμε αλγοριθμική βελτίωση μέσω του λογισμικού εξόρυξης γνώσης και κατηγοριοποίησης που περιγράψαμε. Μέσα από τη διαδικασία αυτή προέκυψε ένας πολύ αποτελεσματικός συνδυασμός ηλεκτροδίων, που τελικά έδωσε την καλύτερη προβλεπτική ικανότητα.

Θα μπορούσαμε ως τελικό αποτέλεσμα, μετά από όλη την ανάλυση που προηγήθηκε στις προηγούμενες παραγράφους, να καταλήξουμε ότι για την πρόβλεψη της δυσκολίας που συναντά κάποιο άτομο κατά τη διάρκεια μιας εκπαιδευτικής διαδικασίας οι καλύτεροι δείκτες για μελέτη και απεικόνιση είναι οι GFP, ERSP και PS με καλύτερους αλγόριθμους ταξινόμησης τους SMO και Part, και καλύτερο αλγόριθμο βελτιστοποίησης τον ConsistencySubsetEval.

Οι μηχανισμοί πρόβλεψης που αναπτύχθηκαν σε αυτή την εργασία μπορούν να χρησιμοποιηθούν, προκειμένου να πυροδοτηθούν συμπεριφορές της διαδικασίας μάθησης, οι οποίες να προσαρμόζονται στη δυσκολία μάθησης. Μπορούν να αναπτυχθούν εκπαιδευτικές διαδικασίες, οι οποίες να εκμεταλλεύονται το γεγονός ότι ο ανθρώπινος εγκέφαλος ενεργοποιείται πριν το άτομο δράσει. Ο ανθρώπινος εγκέφαλος μπορεί να δώσει το σήμα για το μαθησιακό πρόβλημα και μόνο με το γεγονός της αναμονής της διαδικασίας. Ακολουθώντας ένας έξυπνος μηχανισμός επιλογής μαθησιακής δυσκολίας θα μπορούσε να αναπροσαρμόσει τη διαδικασία μάθησης επάνω στο υποκείμενο που εκπαιδεύεται. Ο μηχανισμός επιλογής θα μπορούσε να οδηγείται από συνδυασμό μηχανών συμπερασμού, οντολογικών και άλλων εργαλείων σημασιολογικού ιστού.

Όλα τα προηγούμενα μπορούν να εφαρμοστούν σε διαδικασίες προσαρμοσμένης μάθησης (adaptive learning) για άτομα που αντιμετωπίζουν μαθησιακές δυσκολίες οποιασδήποτε μορφής.

Επιπλέον νέα συμπεράσματα με μεγαλύτερη λεπτομέρεια ενδεχομένως μπορούν να εξαχθούν για τη μέθοδό μας, εάν χρησιμοποιηθούν παράλληλα και



προηγμένες μέθοδοι εγκεφαλικής απεικόνισης, όπως η τομογραφία εκπομπής ποζιτρονίων (PET), η τομογραφία μαγνητικού συντονισμού (MRI) και η λειτουργική τομογραφία μαγνητικού συντονισμού (fMRI) [50], [51], [137]. Με τις μεθόδους αυτές θα έχουμε καλύτερη απεικόνιση για την κατάσταση του εγκεφάλου, τις στιγμές που καταγράφουμε και υπολογίζουμε τους δείκτες. Με την PET είναι δυνατή η απεικόνιση της αιμάτωσης και της λειτουργίας του εγκεφάλου εξαιτίας της σήμανσης της γλυκόζης και των αμινοξέων από τα ποζιτρόνια που εκπέμπονται από τις χρησιμοποιούμενες για τη διαδικασία καταγραφής ουσίες. Η MRI απεικονίζει περιπτώσεις πολλαπλής σκλήρυνσης και άλλων απομυελινωτικών νοσημάτων, αφού μετράει ραδιοσυχνότητες που εκπέμπονται από διάφορα στοιχεία του νευρικού ιστού με την εφαρμογή εξωτερικού μαγνητικού πεδίου. Η fMRI, τέλος, παρέχει πιο λειτουργικές εικόνες από την MRI. Δηλαδή, εκτός από τη δομή του εγκεφάλου δείχνει και τη λειτουργική δραστηριότητά του. Για παράδειγμα, η ροή του αίματος, το οποίο μεταφέρει οξυγόνο και γλυκόζη στις περιοχές του εγκεφάλου που είναι δραστήριες απεικονίζονται στην οθόνη ως κηλίδες φωτός.

Όλες αυτές οι απεικονιστικές μέθοδοι έχουν εφαρμογή στην έρευνα του εγκεφάλου σχετικά με τις διάφορες δυσκολίες που συναντά ο άνθρωπος στις διάφορες δραστηριότητές του. Έτσι έχουν εφαρμογή στην απεικόνιση του εγκεφάλου κατά τη διάρκεια κάποιας εκπαιδευτικής διαδικασίας και στην έρευνα για τις δυσκολίες που συναντά. Αν συνδυστεί η απεικόνιση με τα αποτελέσματα του υπολογισμού των δεικτών και τη στασιμότητα, ίσως μπορέσουν να αποκαλυφθούν περαιτέρω στοιχεία που θα μπορούσαν να βοηθήσουν ακόμα περισσότερο στην πρόβλεψη και στη συνέχεια στην υποβοήθηση της γνώσης και της μάθησης.



# Ψηφιακή Ανάλυση Ηλεκτροεγκεφαλογραφικού Σήματος Εφαρμογές στην Εκπαίδευση

Στεφανίδης Κ. Βασίλειος

## Περίληψη

Στην παρούσα διδακτορική διατριβή αναπτύσσονται μέθοδοι πρόβλεψης μαθησιακών δυσκολιών κατά τη διάρκεια μιας εκπαιδευτικής διαδικασίας, οι οποίες βασίζονται στην ψηφιακή ανάλυση ηλεκτροεγκεφαλογραφικών δεδομένων μέσω κατάλληλων πληροφοριακών συστημάτων και λογισμικών.

Με τη βοήθεια κατάλληλων ψηφιακών μεθόδων ανάλυσης και κατάλληλων πληροφοριακών συστημάτων μελετάμε ηλεκτροεγκεφαλογραφικά σήματα, με σκοπό να ανιχνεύσουμε και να ανακαλύψουμε αλγόριθμους και παραμέτρους που διαφοροποιούν στατιστικά τη δυσκολία την οποία συναντά ένα άτομο, όταν συμμετέχει σε μια εκπαιδευτική διαδικασία. Με τον τρόπο αυτό εξάγονται μοντέλα, τα οποία αποκαλύπτουν και προβλέπουν μαθησιακές δυσκολίες σε μια εκπαιδευτική διαδικασία.

Επιπλέον, μέσα από τη μελέτη της στασιμότητας χρονολογικών σειρών, δίνουμε χρήσιμα συμπεράσματα σχετικά με τη δυνατότητα πρόβλεψης συμπεριφοράς. Στην εργασία αυτή ανιχνεύουμε πειραματικά σημεία στο ηλεκτροεγκεφαλογραφικό σήμα, τα οποία παρουσιάζουν φαινόμενα στασιμότητας.

**Λέξεις-κλειδιά:** Εγκέφαλος, Νόηση, Εκπαίδευση, Ηλεκτροεγκεφαλογράφημα, Μαθησιακές Δυσκολίες, Νευροφυσιολογία, Στάσιμα Κύματα, Συγχρονισμός Δεδομένων



# Digital Electroencephalography Signal Analysis Applications in Education

Stefanidis K. Vasileios

## Summary

The subject of this PhD Thesis is the development of educational difficulties prediction methods during educational procedures. The method is based in electroencephalography (EEG) signals digital analysis through various proper information systems and software.

Using proper digital methods and with help of information systems and software, we study EEG signals in order to investigate proper algorithms, EEG parameters and neurophysiological indexes, which statistical differentiate the difficulty that a person faces when participate in an educational procedure.

In this way we extract mathematical models that reveal and provide learning disabilities in an educational procedure. Furthermore, through the study of stationary time series, we give useful conclusions about the predictability of those people behavior. In this PhD thesis also we detect data points in EEG signal which show stationary phenomena.

**Keywords:** Brain, Cognition, Education, Electroencephalography, Neurophysiology, Learning Difficulties Prediction, Stationary Wavelets, Data Synchronization



## Βιβλιογραφία

1. American Electroencephalographic Society Guidelines Committees, Journal of Clinical Neurophysiology, January 1994 - Volume 11 - Issue 1 - ppg 143-147
2. Alaina H. A., (2010), *EFFECTIVE TEACHING STRATEGIES FOR ALLEVIATING MATH ANXIETY AND INCREASING SELF-EFFICACY IN SECONDARY STUDENTS*, The Evergreen State College, MSc Thesis.
3. Alekseev V. G., (1987) *Symmetry properties of higher spectral densities of stationary random processes*, Mathematical Notes, vol. 41, no. 5, pp. 426-429.
4. Allan Wigfield, Judith L. Meece, (1998), *Math Anxiety in Elementary and Secondary School Students*, Journal of Educational Psychology, Vol. 80, No. 2, 210-216
5. Altman, D. G., Bland, J. M., (1994), *Diagnostic tests. 1: Sensitivity and specificity*, British Medical Journal, 308(6943): 1552.
6. Arenas, A., Daz-Guilera, A., Kurths, J., Moreno, Y., Zhou, C., (2008), *Synchronization in complex networks*, Physics Reports, 469 (3), 93-153.
7. Aydin S., Saraog Lu H. M., Kara S., (2009), *Log energy entropy-based EEG classification with multilayer neural networks in seizure*, Annals of Biomedical Engineering, Vol. 37, No. 12.
8. Baars, B. J., Gage, N. M., (2010), *Cognition, Brain, and Consciousness: Introduction to Cognitive Neuroscience*, Elsevier, 2nd Edition
9. Bethea, R. M, and Rhinehart, R. R., (1991) Applied Engineering Statistics, Marcel Dekker, Inc., New York.
10. Bein B., (2006), *Entropy*, Best practice & Research Clinical Anaesthesiology Vol.20, No 1, pp. 101-109, ELSEVIER.
11. Blackman, R. B. and Tukey J. W., (1959), *The Measurement of Power Spectra from the Point of View of Communication Engineering*, New York: Dover.
12. Boyce W. M., (1969), *Commuting functions with no common fixed point*, Transactions of the American Mathematical Society, pp 7792.
13. Boyer, R.H., Lindquist, R.W., (1967), *Maximal analytic extension of the Kerr metric*, Journal of mathematical physics, 265281.

14. Brandwein, A.B., Foxe, J.J., Butler, J.S., Frey, H.-P., Bates, J.C., Shulman, L.H., Molholm, S., (2015), *Neurophysiological Indices of Atypical Auditory Processing and Multisensory Integration are Associated with Symptom Severity in Autism*, Journal of autism and developmental disorders, Vol. 45, pp. 230244.
15. Bronez, T. P., (1992), *On the performance advantage of multitaper spectral analysis*, IEEE Transactions on Signal Processing.
16. Broomhead, D., Lowe, D., (1988), *Multivariable fractional interpolation and adaptive networks*, Complex Systems.
17. Bu, X., Qiao, R., Han, D. , Thinking Ability Visualization Model Based on Wechsler Intelligence Scale for Children, Intelligent Human-Machine Systems and Cybernetics (IHMSC), Sixth International Conference on. IEEE, pp. 237240, 2014.
18. Burg, J. P., (1972), *The relationship between maximum entropy spectra and maximum likelihood spectra*, Geophysics.
19. Burg, J. P., (1975), *Maximum Entropy Spectral Analysis*, Ph. D. thesis, Stanford University.
20. Calvez, L. C., Vilbe, P., (1992), *On the uncertainty principle in discrete signals*, IEEE Transactions on Circuits and Systems 39 (6), 394-395.
21. Campbell J.I.D., (2005) *Handbook of Mathematical Cognition*, Psychology Press.
22. Cantoni, A., Butler, P., (1976), *Eigenvalues and eigenvectors of symmetric centrosymmetric matrices*, Linear Algebra and its Applications 13 (3), 275-288.
23. Capon, J. (1969), *High-resolution frequency-wavenumber spectrum analysis*, Proceedings of the IEEE 57 (8), 1408-1418.
24. Challis, R. E., and Kitney, R. I., (1991), *Biomedical signal processing (in four parts). Part 1 Time-domain methods*, Medical & Biological Engineering & Computing, vol.28, pp. 509-524.
25. Chikwasha V., (2005), *Time Series Analysis Using Wavelets and Entropy Analysis*, BMC bioinformatics, n.10, v.32.
26. Choi, Y.P., Ha, S.Y., Jung, S., Kim, Y., (2012), *Asymptotic formation and orbital stability of phase-locked states for the Kuramoto model*, Elsevier, Physica, D 241, pp. 735754.



27. Cover, T.M., (1965), *Geometrical and statistical properties of systems of linear inequalities with applications in pattern recognition*, IEEE Trans Electron Comput, 14:326-334.
28. Cochrane, J. H., (1991), *A critique of the application of unit root tests*, Journal of Economic Dynamics and Control, v. 15, No. 2, pp 275–284.
29. Daube J. R, Rubin D.I, (2009), *Clinical Neurophysiology*, Oxford University Press, Third Edition.
30. DeGraaf, S. R., (1994), *Sidelobe reduction via adaptive FIR filtering in SAR imagery*, IEEE Transactions on Image Processing 3 (3), 292-301.
31. Delorme A., S. Makeig, (2004), *EEGLAB: an open source toolbox for analysis of single-trial EEG dynamics including independent component analysis*, Journal of Neuroscience Methods 134.
32. Doroslovacki, M. I. (1998), *Product of second moments in time and frequency for discretetime signals and the uncertainty limit*, Signal Processing 67 (1), 59-76.
33. Dumermuth, G., Molinary, L., (1987), *Spectral Analysis of EEG Background Activity*, In Handbook Methods of Analysis of Brain Electrical and Magnetic Signals, A. S. Gevins (ed.) (Amsterdam: Elsevier).
34. Durbin, J. (1959), *Efficient estimation of parameters in moving-average models*, Biometrika 46, 306-316.
35. Durbin, J. (1960), *The Fitting of time series models*, Review of the International Institute of Statistics 28, 233-244.
36. Fabre-Thorpe M., Delorme A., Marlot C., Thorpe C., (2003), *A Limit to the Speed of Processing in Ultra Rapid Visual Categorization of Novel Natural Scenes*, Journal of Cognitive Neuroscience, 13(2), 171-180.
37. Felzer, T., (2001), *On the possibility of developing a brain-computer interface (bci)*, Technical University of Darmstadt, Department of Computer Science.
38. Folias S. E., Bressloff P. C., (2005), *Breathers in two-dimensional neural media*, Physical review letters, vol. 95, no. 20.
39. Frantzidis C. A, Bratsas C., Klados M., Konstantinidis E., Lithari C. D., Vivas A. B., Papadelis C., Kaldoudi E., Pappas C., Bamidis P. D, (2010), *On the classification of emotional biosignals evoked while viewing affective pictures: an integrated data mining based approach for healthcare applications*, Information Technology in Biomedicine, IEEE Transactions, Vol. 14, Iss. 2.

40. Gersh, W., (1970), *Estimation of the autoregressive parameters of mixed autoregressive moving average time series*, IEEE Transactions on Automatic Control AC{15(5), 583-588.
41. Giannakakis, G.A., Tsiaparas, N., Xenikou, M.-F.S., Papageorgiou, C., Nikita, K.S., (2008), *Wavelet entropy differentiations of event related potentials in dyslexia*, 8th IEEE International Conference on BioInformatics and BioEngineering.
42. Gold, J., (2014), *Intellectual decline in schizophrenic patients*.
43. Goldman-Mellor, S., Caspi, A., Gregory, A.M., Harrington, H., Poulton, R., Moffitt, T.E., (2014), *Is Insomnia Associated with Deficits in Neuropsychological Functioning? Evidence from a Population-Based Study*.
44. Gmez-Gardenes, J., Moreno Y., Arenas, A., (2007), *Paths to Synchronization on Complex Networks*, Phys. Rev. Lett., 98.
45. Hayes M. H., (1996), *Statistical Signal Processing and Modeling*, John Wiley and Sons.
46. Hirsch L. J., Richard P., Brenner R.P., (2010), *Atlas of EEG in Critical Care*, Wiley-Blackwell.
47. Huang R. S., Tsai L.L, Chung J. Kuo C. J., (2001), *Selection of Valid and Reliable EEG Features for Predicting Auditory and Visual Alertness Levels*, Proc. Natl. Sci. Counc. ROC(B), Vol. 25, No. 1.
48. Jenkins, G. M., Watts D. G. (1968), *Spectral Analysis and its Applications*, San Francisco, CA: Holden-Day.
49. Kahle W., Frotscher M., (2003), *Nervous System and Sensory Organs*, Thieme, Frankfurt Germany, vol. 3, 5th edition.
50. Kandel E.R., Schwartz J.H., Jessell T.M. (2000), *Principles of Neural Science*, 4th ed. McGraw-Hill, New York.
51. Kandel E.R., Schwartz J.H., Jessell T.M. (1995), *Essentials of Neural Science and Behavior*, McGraw-Hill, New York.
52. Kaplan A. Y. ,Fingelkurts A. A.,Fingelkurts A. A.,Borisov S. V. and Darkhovsky B. S., (2005), *Nonstationary nature of the brain activity as revealed by EEG/MEG: methodological, practical and conceptual challenges*. Signal processing, n. 85, vol. 11, pp 2190 – 2212.

53. Kleinberg, J., (2000), *Complex networks and decentralized search algorithms*, Mathematics Subject Classification.
54. Kohonen, T., (1995), *Self-Organizing Maps*, Berlin - Heidelberg: Springer-Verlag.
55. Kramer, D., Schmutzer, E., (1980), *Exact solutions of Einsteins field equations*, Cambridge University Press Cambridge.
56. Kreuz, T., Mormann, F., Andrzejak, R. G., Kraskov, A., Lehnertz, K., Grassberger, P., Measuring synchronization in coupled model systems: A comparison of different approachs, *Physica D*, vol. 225, no. 1, pp. 2942, 2007.
57. Kuramoto, Y., (1975), *International Symposium on Mathematical Problems in Mathematical Physics*, Lecture notes in theoretical Physics, vol. 30, p. 420.
58. Kwiatkowski D., Phillips, P. C. B , Schmidt, P., Shin, Y. (1992), *Testing the null hypothesis of stationarity against the alternative of a unit root: How sure are we that economic time series have a unit root?*, *Journal of econometrics*, vol. 54, no. 1, pp. 159–178.
59. Lehmann D., Skrandies W., (1980), *Reference-free identification of components of checkerboard-evoked multichannel potential fields*, *Electroencephalography Clinical Neurophysiology*, Vol. 48, pp. 609.
60. Lehmann, D., Skrandies, W., (1984), *Spatial analysis of evoked potentials in man- a review*, *Prog Neurobiol*, Vol. 23, pp. 227.
61. Levinson, N., (1947), *The Wiener RMS (root mean square) criterion in filter design and prediction*, *Journal of Math. and Physics* 25, 261.
62. Lin, A., Northam, E.A., Werther, G.A., Cameron, F.J., Risk Factors for Decline in IQ in Youth With Type 1 Diabetes Over the 12 Years From Diagnosis/Illness Onset, *Diabetes care*, Vol. 38, pp. 236242, 2015.
63. Liu, Y.Y., Slotine, J.J., Barabasi, A.L., (2011), *Controllability of Complex Networks*, *Nature International Journal of sciences*.
64. Lopez da Silva F. H., Storm Van Leeuwen W., & Remond A., «Handbook of electroencephalography and clinical neurophysiology: Vol. 2.», Elsevier, 1990.
65. Lysenko, V., (2012), *Proceedings of the 7th International Conference on Information Warfare and Security*, Academic Conferences Limited, Ελευθερουδάκης, Παπασωτηρίου

66. Makeig S., S. Debener, J. Onton, A. Delorme, «Mining event-related brain dynamics», *TRENDS in Cognitive Sciences*, Vol. 8 No 5, May 2004
67. Malmivuo J., Plonsey R. (1995), *Bioelectromagnetism - Principles and Applications of Bioelectric and Biomagnetic Fields*, Oxford University Press, New York.
68. Mammarella, I., Ghisi, M., Bomba, M., Bottesi, G., Caviola, S., Broggi, F., Nacinovich, R., (2014), *Anxiety and Depression in Children With Nonverbal Learning Disabilities, Reading Disabilities, or Typical Development*, *Journal of Learning Disabilities*.
69. Marcel, S., Milln, J. del R., (2007), *Person authentication using brainwaves (EEG) and maximum a posteriori model adaptation. Pattern Analysis and Machine Intelligence*, *IEEE Transactions on* 29, 743 - 752.
70. Masliah, M. R. (1998), Stationarity/nonstationarity identification.  
[http://docencia.izt.uam.mx/mjgg/Proc\\_Senales\\_Est/material\\_adicional/Stationarity%20testing.doc](http://docencia.izt.uam.mx/mjgg/Proc_Senales_Est/material_adicional/Stationarity%20testing.doc).
71. Mayne, D. Q., Firoozan, F. , (1982), *Linear identification of ARMA processes*, *Automatica* 18, 461-466.
72. McArdle, J.J., Hamagami, F., (1992), *Modeling incomplete longitudinal and cross-sectional data using latent growth structural models*, *Experimental aging research* 18, 145 - 166.
73. McArdle, J.J.,(2015), *Measurement Invariance*, *The Encyclopedia of Clinical Psychology*.
74. Mendonca, M.W., (2009), *Multilevel Optimization: Convergence Theory, Algorithms and Application to Derivative-Free Optimization*, Phd thesis, Facults Universitaires Notre-Dame de la Paix, Namur, Belgium.
75. Meece, J., (1981), *Individual differences in the affective reactions of middle and high school students to mathematics: A social cognitive perspective*, Unpublished doctoral dissertation, University of Michigan.
76. Misulis K. E., MD, Head T. C.,(2002), *Essentials of Clinical Neurophysiology Third edition*, Semmes-Murphey Clinic, Vanderbilt University, & University of Tennessee, Memphis.
77. Mitra S. K., (2006), *Digital Signal Processing: A Computer-Based Approach*, McGraw Hill Higher Education, 3rd edition.
78. Mormanna, F., Lehnertz, K., David, P., Elger, C. E., (2000), *Mean phase coherence as a measure for phase synchronization and its application to the EEG of epilepsy patients*, Elsevier, Physica D.

79. Muller, M. F., Rummel, C., Goodfellow M., Schindler, K., [], *Standing Waves as an Explanation for Generic Stationary Correlation Patterns in Noninvasive EEG of Focal Onset Seizures*, Brain Connectivity, Vol. 4, Number 2.
80. Neugebauer, G., (1980), *Recursive calculation of axially symmetric stationary Einstein fields*, Journal of Physics A: Mathematical and General.
81. Nilsson, N., (1988), *Learning Machines-Foundations Pattern-classifying Systems*.
82. Norman, Morisson, (1994), *Introduction to Fourier Analysis*, Copyright by John Wiley & Sons, Inc.
83. Oehlert, G. W., (1992), *A Note on the Delta Method*, The American Statistician, Vol. 46, No. 1, p. 27-29.
84. Oie, M., Rund, B.R.,(2015), *Neuropsychological deficits in adolescent-onset schizophrenia compared with attention deficit hyperactivity disorder*.
85. Oken, B.S., (2004), *Complementary Therapies in Neurology*, The Parthenon Publishing Group International Publishers in Medicine, Science & Technology press company London, New York, Washington, d.c.
86. Oppenheim A. V., Schafer R. W., (1999), *Discrete-time signal processing*, Prentice Hall, 2nd edition.
87. Oxtoby J. C., Ulam, S. M., (1941), *Measure-preserving homeomorphisms and metrical transitivity*, Annals of Mathematics.
88. Palaniappan, R., (2005), *Brain computer interface design using band powers extracted during mental tasks. Neural Engineering*, Conference Proceedings, 2nd International IEEE EMBS Conference on. IEEE, pp. 321 - 324.
89. Papavlasopoulos S. H., Poulos M. S., Bokos G. D., Evangelou A. M.,(2006), *Classification Control for Discrimination between Interictal Epileptic and Non-Epileptic Pathological EEG Events*, International Journal of Biological and Medical Sciences, vol. 1, no. 1, pp. 34-41.
90. Parasuraman R., Rizzo M., (2007), *Neuroergonomics - The Brain at Work*, Oxford University Press, Third Edition.
91. Padovani T., Koenig T., Brandeis D., Perrig W.J.,(2011), *Different Brain Activities Predict Retrieval Success during Emotional and Semantic Encoding*, Journal of Cognitive Neuroscience, Volume 23, Number 12.

92. Percival, D. B., Walden, A. T., (1993), *Spectral Analysis for Physical Applications Multitaper and Conventional Univariate Techniques*, Cambridge, England: Cambridge University Press.
93. Petrantonakis, P. C., and Hadjileontiadis, L. J. , EEG-Based Emotion Recognition Using Advanced Signal Processing Techniques, in *Advances in Emotion Recognition*, A. Konar and A. Chakraborty (Eds.), New York, NY: Wiley-Blackwell Press, 2013.
94. M. Poulos, (2001), *On the use of EEG features towards person identification via neural networks*, Informatics for Health and Social Care, v. 26, n. 1.
95. Poulos, M., Georgiacodis, F. , Chrissikopoulos, V., Evangelou, A. (2003) *Diagnostic test for the discrimination between interictal epileptic and non-epileptic pathological EEG events using auto-cross-correlation methods*, American journal of electroneurodiagnostic technology, vol. 43, no. 4, pp. 228-240.
96. Poulos, M., Rangoussi, M., Alexandris, N., (1999a), *Neural network based person identification using EEG features. Acoustics, Speech, and Signal Processing*, Proceedings., IEEE International Conference on. IEEE.
97. Poulos, M., Rangoussi, M., Chrissikopoulos, V., Evangelou, A., (1999b), *Parametric person identification from the EEG using computational geometry. Electronics, Circuits and Systems*, Proceedings of ICECS99. The 6th IEEE International Conference on. IEEE, pp. 1005 - 1008.
98. Poulos, M., Rangoussi, M., Chrissikopoulos, V., Evangelou, A., (1999c), *Person identification based on parametric processing of the EEG. Electronics, Circuits and Systems*, Proceedings of ICECS99. The 6th IEEE International Conference on. IEEE, pp. 283 - 286.
99. Poulos, M., Rangoussi, M., Alexandris, N. and Evangelou, A., (2001), *On the use of EEG features towards person identification via neural networks*, Informatics for Health and Social Care, Vol. 26, No. 1 pp. 35-48.
100. Poulos, M., Rangoussi, M., Chrissikopoulos, V., Evangelou, A., (2001), *EEG spectrum analysis for the extraction of approximately stationary features*, Proceedings of the 5th International Workshop of Scattering and Biomedical Engineering, Modeling and Applications World Scientific, pp. 1819.
101. Poulos, M., Rangoussi, M., Chrissikopoulos, V., Evangelou, A., Georgiacodis, F., (2004), *Comparative analysis of the computational geometry and neural network classification methods for person identification purposes via the EEG: Part 1*, Journal of Discrete Mathematical Sciences and Cryptography 7, 319 - 347.

102. Poulos, M., Papavlasopoulos S., Alexandris N., Vlachos E.,(2004), *Comparison between auto-cross-correlation coefficients and coherence methods applied to the EEG for diagnostic purposes*, Medical Science Monitor, vol. 10, no. 10, pp. 99-108.
103. Poulos, M., Papavlasopoulos S.,(2013), *Automatic stationary detection of time series using auto-correlation coefficients and LVQ—Neural network*, in Information, Intelligence, Systems and Applications (IISA), Fourth International Conference on, pp 1–4.
104. Priestley, M. B., (1981), *Spectral Analysis and Time Series*, London, England: Academic Press.
105. Proakis J. G., Manolakis D. G. (2007), *Digital Signal Processing : Principles, Algorithms, and Applications*, Prentice Hall, 4th edition.
106. Quiroga, R. Q., Kraskov, A., Kreuz, T., Grassberger, P., (2002), *Performance of different synchronization measures in real data: A case study on electroencephalographic signals*, Phys., Rev. E, vol. 65, no. 4, p. 041903.
107. Rigas, G., Katsis, C. D., Ganiatsas, G., Fotiadis, D. I., (2007), *A User Independent, Biosignal Based, Emotion Recognition Method*, Lecture Notes in Computer Science, Vol. 4511, pp. 314-318.
108. Ritt, J. F., (1923), *Permutable rational functions*, Trans. Amer. Math. Soc. 25, pp 399 - 448.
109. Sakkalis V., Zervakis M., Micheloyannis S.,(2006), *Significant EEG Features Involved in Mathematical Reasoning: Evidence from Wavelet Analysis*, Brain Topography, Volume 19.
110. Sanei S. and Chambers, J.A. ., «EEG Signal Processing England», Wiley and Sons Ltd, 2007
111. Shafer, V., Ponton, C., Datta, H., Morr, M., Schwartz R., (2007), *Neurophysiological indices of attention to speech in children with specific language impairment*, International Journal of Clinical Neurophysiology, Vol. 118, No. 6, pp.1230–1243.
112. Skrandies, W., (2005), *Brain Mapping of Visual Evoked Activity - Topographical and Functional Components*, Acta Neurologica Taiwanica, Vol 14, No 4, Dec.
113. Smith, M., McEvoy, L., Gevins, A., (1999), *Neurophysiological indices of strategy development and skill acquisition*, Journal of Cognitive Brain Research, Vol. 7, No. 3, pp.389–404.

114. So H. C., Chan Y. T., Ma Q., Ching P. C., (199), *Comparison of various periodograms for sinusoid detection and frequency estimation*, Aerospace and Electronic Systems, IEEE Transactions on, vol. 35, no. 3, pp. 945–952.
115. Stoica, P., Friedlander, B., Soderstrom, T., (1987), *Approximate maximum-likelihood approach to ARMA spectral estimation*, International Journal of Control 45 (4), 1281-1310.
116. Subba, Rao, T., (1977), *On the estimation of bilinear time series models*, Bull Inst. Int. Stat.; 41: 125-158.
117. Sun, J., Hong, X., Tong, S., (2012), *Phase synchronization analysis of EEG signals: an evaluation based on surrogate tests*, IEEE Transactions Biomedical Engineering.
118. Swami, A., Mendel, M., (1989), *AR Identification using Cumulants*, In Proceedings Workshop on Higher-Order Spectral Analysis, Vail, Colorado, USA, April 1989, 1, 1-6
119. Swash, M. and de Carvalho, M., *The Neurophysiological Index in ALS*, Journal of Amyotrophic Lateral Sclerosis and Other Motor Neuron Disorders, Vol. 1, No. 108, 2008.
120. Tanaka, K., Mizuno, Y. Tanaka T., Kitajo K., (2013), *Detection of phase synchronization in EEG with Bivariate Empirical Mode Decomposition*, Conference Proceedings IEEE Engineering Medical Biology Society, 973-976.
121. Thatcher R.W., North D., Biver C., (2002), *EEG DISCRIMINANT ANALYSES OF CHILDREN WITH LEARNING DISABILITIES: CORRELATIONS TO SCHOOL ACHIEVMENT AND NEUROPSYCHOLOGICAL PERFORMANCE*,
122. Wang C., Xu J., Lou W., Zhao S., (2014), *Dynamic information flow analysis in Vascular Dementia patients during the performance of a visual oddball task*, Neuroscience letters.
123. Winfree, A.T., (1967), *Biological rhythms and the behavior of populations of coupled oscillators*, Journal of Theoretical Biology, 16 : 1542.
124. Winterhalder, M., Schelter, B., Kurths, J., Schulze-Bonhage, A., (2006), *Timmer, Sensitivity and specificity of coherence and phase synchronization analysis*, Phys. Lett. A, vol. 356, pp. 2634.
125. Ying, C. J., Potter, L. C., Moses R., (1994), *On model order determination for complex exponential signals: Performance of an FFT-initialized ML algorithm*, in Proceedings of IEEE Seventh SP workshop on SSAP, Quebec City, Quebec, pp. 43-46.



126. Zadeh, L., (1996), *Fuzzy Sets, Fuzzy Logic, and Fuzzy Systems*, World Scientific Publishing Co Pte Ltd. Vol.6, Singapore.
127. Zar J. H.,(1999), *Biostatistical analysis*, τ. 564. Prentice Hall Upper Saddle River, NJ.
128. Zervakis M, Michalopoulos K, Iordanidou V, Sakkalis V.,(2011), *Intertrial coherence and causal interaction among independent EEG components*, Journal of Neuroscience Methods.
129. Zygierewicz J.,Mazurkiewicz J.,Durka P. J.,Franaszczuk P. J. and Crone N. E.,(2006), *Estimation of short-time cross-correlation between frequency bands of event related EEG*, Journal of neuroscience methods 157, vol. 2, pp 294 - 302.
130. Γαλάνης Δ., (2008), *Ανίχνευση Ρυθμών σε Ηλεκτροεγκεφαλογράφηματα*, Μεταπτυχιακή Εργασία, Παν/μιο Πατρών.
131. Γιαννακάκης Γ., (2005), *Ανάλυση ηλεκτροεγκεφαλογραφικού σήματος με εφαρμογές στην επιληψία και τις μαθησιακές δυσκολίες*, Μεταπτυχιακή Εργασία, Παν/μιο Πατρών, Τμήμα Ιατρικής, Εθνικό Μετσόβιο Πολυτεχνείο, Σχολή Ηλεκτρολόγων Μηχ/κων και Μηχ/κων Η/Υ, 2005.
132. Γιαννακάκης Γ., (2009), *Ανάπτυξη μεθόδων ανάλυσης ηλεκτροεγκεφαλογραφικού σήματος με χρήση μοντέλων συνδεσιμότητας και μεγεθών εντροπίας*, Διδακτορική Διατριβή, Παν/μιο Πατρών, Τμήμα Ιατρικής, Εθνικό Μετσόβιο Πολυτεχνείο, Σχολή Ηλεκτρολόγων Μηχ/κων και Μηχ/κων Η/Υ.
133. Καρκαλούσος Π., Δελίχα Ε., «Παρουσίαση και εφαρμογές της προσεγγιστικής εντροπίας (ApEn) στην Ιατρική», Αρχεία Ελληνικής Ιατρικής 2004, 21(2): 161-171.
134. Κλάδος Μ., «Επεξεργασία Ηλεκτροεγκεφαλικών Σημάτων-Υβριδικές Μέθοδοι Καθαρισμού των Οφθαλμικών Παρασίτων», MSc Thesis, Αριστοτέλειο Πανεπιστήμιο Θεσσαλονίκης, 2009.
135. Μιχελογιάννης, Τζενάκη Ι., Βάμβουκας Μ., Παρίσης Μ. Ι., Γιαχνάκης Ν., Προκοπάκης Ε., (2008), *Το ηλεκτροεγκεφαλογράφημα σε παιδιά με μαθησιακές δυσκολίες*, Παιδαγωγική Εταιρεία Ελλάδος.
136. Νασιώτης Κ., «Αναγνώριση Συναισθηματικών Καταστάσεων από Ηλεκτροεγκεφαλογράφημα Χρησιμοποιώντας Διαφορετικά Διανύσματα Χαρακτηριστικών», Διπλωματική Εργασία, Αριστοτέλειο Πανεπιστήμιο Θεσσαλονίκης, 2011
137. Ντινόπουλος Θ., (2008), *Νευροηθική*, Εκδ. Παρισιάνου, Αθήνα.

138. Ξενικού Μ. Φ., Επ : Κ. Νικήτα, (2009), *Μελέτη Ηλεκτροεγκεφαλογραφήματος με βάση μεγέθη από τη θεωρία πληροφορίας*, Μεταπτυχιακή Διπλωματική Εργασία, ΕΚΠΑ Αθήνα.
139. Παλαιορούτα Α., (2009), *Ανάλυση ηλεκτροεγκεφαλογραφημάτων μέσω της μεθόδου ανεξάρτητων συνιστωσών*, Μεταπτυχιακή Διπλωματική Εργασία, Πανεπιστήμιο Πατρών.
140. Περικλειδάκης Γ. Α., (2003), *Μαθησιακές δυσκολίες στα Μαθηματικά σε παιδιά Δημοτικού Σχολείου με κανονική νοημοσύνη – Δυσαριθμησία (Διάγνωση . Αντιμετώπιση, Διδακτορική Διατριβή, Ρέθυμνο.*
141. Ρίζος, Γ., (1996), *Τεχνητά Νευρωνικά Δίκτυα, Θεωρία και Εφαρμογές, Εκδόσεις Νέων Τεχνολογιών, Αθήνα.*
142. Τζουριάδου, Μ. (...), *ΠΡΟΣΑΡΜΟΓΕΣ ΑΝΑΛΥΤΙΚΩΝ ΠΡΟΓΡΑΜΜΑΤΩΝ ΓΙΑ ΜΑΘΗΤΕΣ ΜΕ ΜΑΘΗΣΙΑΚΕΣ ΔΥΣΚΟΛΙΕΣ*, 2ο Επιχ. Πρόγραμμα Εκπαίδευσης και Αρχικής Κατάρτισης, ΥΠΕΠΘ
143. Τζουριάδου, Μ. (2011). *Μαθησιακές Δυσκολίες: Θέματα ερμηνείας και αντιμετώπισης*, Θεσσαλονίκη, Εκδόσεις "Προμηθεύς"
144. Τσακάλη Ε., (2008), *Υπολογισμός καρδιακού ρυθμού με ψηφιακή επεξεργασία βίντεο στο υπέρυθρο φάσμα*, Μεταπτυχιακή Διπλωματική Εργασία, Μεταπτυχιακή Πανεπιστήμιο Πατρών.
145. Τσιρογιάννης Γ. Α., (2003), *Ευφυές σύστημα συνδυασμού μεθόδων ταξινόμησης για ιατρική διάγνωση*, Διπλωματική Εργασία, Εθνικό Μετσόβιο Πολυτεχνείο, Αθήνα.
146. Φραντζίδης Χ., (2008), *Τεχνικές ανίχνευσης συναισθηματικού περιεχομένου από νευρο-φυσιολογικά δεδομένα*, MSc Thesis, Αριστοτέλειο Πανεπιστήμιο Θεσσαλονίκης, 2008.
147. 32-electrodes cap  
[https://www.ant-neuro.com/sites/default/files/images/waveguard\\_layout\\_032ch.png](https://www.ant-neuro.com/sites/default/files/images/waveguard_layout_032ch.png)
148. Electroencephalography  
<http://www.bem.fi/book/13/13.htm>
149. «ENTROPY HANDBOOK Definitions, Theorems, M-files»  
[www.uivt.cas.cz/~pklan/eth.pdf](http://www.uivt.cas.cz/~pklan/eth.pdf)
150. EEGLab 12th Workshop  
[http://sccn.ucsd.edu/wiki/Twelfth\\_EEGLAB\\_Workshop](http://sccn.ucsd.edu/wiki/Twelfth_EEGLAB_Workshop)
151. EEG microstates  
[http://www.scholarpedia.org/article/EEG\\_microstates](http://www.scholarpedia.org/article/EEG_microstates)

(τελευταία πρόσβαση 9/12/2012)

152. EEGLAB Matlab Toolbox  
<http://sccn.ucsd.edu/eeglab/>
153. EEGLAB- tutorial,  
<http://sccn.ucsd.edu/eeglab/eeglabtut.html>
154. EEGLab Wiki  
<http://sccn.ucsd.edu/wiki/Eeglab>
155. Hans Berger  
[http://en.wikipedia.org/wiki/Hans\\_Berger](http://en.wikipedia.org/wiki/Hans_Berger)
156. Hyndman, R.J. Time Series Data Library,  
<http://data.is/TSDLdemo>
157. Mathstat  
[http://www.mathstat.dal.ca/~stat5390/Section\\_4\\_PSD1.pdf](http://www.mathstat.dal.ca/~stat5390/Section_4_PSD1.pdf)
158. Matlab polyfit  
<http://www.mathworks.com/help/matlab/ref/polyfit.html?requestedDomain=www.mathworks.com>
159. Phase Locking Value (PLV,  
[http://www.nbtwiki.net/doku.php?id=tutorial:phase\\_locking\\_value#.VYMOdVKbrMo](http://www.nbtwiki.net/doku.php?id=tutorial:phase_locking_value#.VYMOdVKbrMo).
160. SPSS Statistics, software package for statistical analysis  
<http://www-01.ibm.com/software/analytics/spss/>
161. The wavelet packet method is a generalization of wavelet decomposition that offers a richer signal analysis.  
<http://www.mathworks.com/help/wavelet/ug/wavelet-packets.html#f8-22572>
162. WEKA (Περιβάλλον Εξόρυξης Γνώσης)  
<http://www.cs.waikato.ac.nz/ml/weka/>
163. Άδεια GNU/GPL  
<http://www.gnu.org/licenses/gpl.html>
164. Ανάλυση Διακύμανσης, Πανάρετος Γιάννης, Καθηγητής Πιθανοτήτων και Στατιστικής, Τμήμα Στατιστικής, Οικονομικό Πανεπιστήμιο Αθηνών, Σημειώσεις Μαθήματος.  
<http://stat-athens.aueb.gr/~jpan/>
165. Εντροπία Δείγματος (Sample Entropy)

<http://www.mathworks.com/matlabcentral/fileexchange/35784-sample-entropy>

166. Επεξηγήσεις λειτουργίας ταξινομητών WEKA (WEKA classifiers)  
<http://wiki.pentaho.com/display/DATAMINING/AdaBoostM1>

167. Η πλαστικότητα του Εγκεφάλου και το σύστημα γραφής Braille  
Α. Καραβάτος, Α' Ψυχιατρική Κλινική Α.Π.Θ  
[http://amea-edu.blogspot.gr/2009\\_03\\_01\\_archive.html](http://amea-edu.blogspot.gr/2009_03_01_archive.html)

168. Κυματιδιακές Εντροπίες (Wavelet Entropies)  
<http://www.mathworks.com/help/wavelet/ref/wentropy.html>

169. Μαθησιακές δυσκολίες και γνωστικές προσεγγίσεις,  
Τζουριάδου, Μ., Μπάρμπας Γ.,  
<http://www.kairosnet.gr/joomla/docs/mathisiakes-tzouriadou-barbas.pdf>

170. ταξινομητές WEKA (WEKA classifiers)  
<http://weka.sourceforge.net/doc/weka/classifiers/Classifier.html>

171. Δεδομένα πειράματος  
[http://sccn.ucsd.edu/~arno/fam2data/publicly\\_available\\_EEG\\_data.html](http://sccn.ucsd.edu/~arno/fam2data/publicly_available_EEG_data.html)

## Παράρτημα Α


### Γενικά για το WEKA

Το περιβάλλον WEKA (Waikato Environment for Knowledge Learning), είναι [162] ένα ολοκληρωμένο σύστημα που αναπτύχθηκε στο Πανεπιστήμιο Waikato της Νέα Ζηλανδίας, με σκοπό τον προσδιορισμό των πληροφοριών από την επεξεργασία των στοιχείων που συγκεντρώθηκαν από το γεωργικό τομέα. Υποστηρίζει πολλά διαφορετικά τυποποιημένα εργαλεία εξόρυξης δεδομένων ή εξόρυξης γνώσης, όπως η προεπεξεργασία στοιχείων, η ταξινόμηση, η ομαδοποίηση, η οπισθοδρόμηση, η απεικόνιση και η επιλογή χαρακτηριστικών γνωρισμάτων. Η βασική αρχή του προγράμματος είναι να χρησιμοποιεί μια ομάδα δεδομένων η οποία μπορεί να εκπαιδευθεί, με σκοπό να επιτελέσει μηχανική μάθηση και τελικά να παράγει χρήσιμες πληροφορίες. Το WEKA είναι πρόγραμμα ανοιχτού λογισμικού και επομένως είναι ελεύθερο στη χρήση, κάτω από την άδεια GNU/GPL [163].

Αναπτύχθηκε αρχικά σε C, όμως στη συνέχεια ξαναγράφηκε σε Java, ώστε να μπορεί να εκτελείται σε περισσότερες πλατφόρμες. Σήμερα υπάρχει έκδοση για όλα τα γνωστά λειτουργικά συστήματα (Linux, Windows και Mac OS).

Σύμφωνα με τους δημιουργούς του, η εφαρμογή WEKA παρέχει στους αρχάριους χρήστες ένα εργαλείο για να εντοπίσουν τις κρυφές πληροφορίες από βάσεις δεδομένων και συστήματα αρχείων με απλό τρόπο.

## «Ψηφιακή Ανάλυση Ηλεκτροεγκεφαλογραφικού Σήματος (ΗΕΓ) Εφαρμογές στην Εκπαίδευση»



Εικόνα 86: Η παρουσία του WEKA στο διαδίκτυο

Ανοίγει στο είδος των εφαρμογών που ονομάζονται εφαρμογές «εξόρυξης δεδομένων». Η εφαρμογή μπορεί να χρησιμοποιηθεί ποικιλοτρόπως. Παρέχει εφαρμογές οι οποίες θεωρούνται αυτό που λέμε «state of the art». Πιο συγκεκριμένα, αλγορίθμους για discretization, αλγόριθμους για προεπεξεργασία δεδομένων, έτσι ώστε να τροφοδοτηθεί ένα σχέδιο εκμάθησης, αλγόριθμους ταξινόμησης κ.τ.λ..

Ένας τρόπος χρήσης της εφαρμογής Weka είναι να εφαρμόσει τη μέθοδο μάθησης σε ένα σύνολο δεδομένων και να αναλύσει τα αποτελέσματα τους για να εξάγει πληροφορίες που αφορούν τα δεδομένα. Μια άλλη χρήση της εφαρμογής είναι να επιτρέψει στους αρχάριους χρήστες να συγκρίνουν τις επιδόσεις τους, προκειμένου να επιλέξουν το καταλληλότερο μοντέλο για πρόβλεψη. Οι αλγόριθμοι μάθησης καλούνται ταξινομητές (classifiers.). Όλοι εκτελούνται από την ίδια διεπαφή. Η τελική απόδοσή τους μετράται από μια κοινή ενότητα.


### Ανοίγοντας το WEKA

Ξεκινώντας της εφαρμογή υπάρχουν τέσσερις επιλογές διαθέσιμες την αρχική οθόνη (*Εικόνα 35*):

- **Explorer:** είναι η γραφική διεπαφή του WEKA
- **Experimenter:** με την επιλογή αυτή μπορούν να πραγματοποιηθούν διάφορες πειραματικές και στατιστικές διεργασίες στα σύνολα στοιχείων.
- **Knowledge Flow:** είναι μια παρόμοια γραφική διεπαφή με τον Explorer. Υποστηρίζει μια άλλη τεχνική εκμάθησης, την αυξητική η οποία στηρίζεται στη γνώση από τα προηγούμενα αποτελέσματα.
- **Simple CLI:** δίνει τη δυνατότητα λειτουργίας σε command line

### Ανοίγοντας τον Explorer

Στη συνέχεια επιλέγοντας το κουμπάκι Explorer, ανοίγει η οθόνη της *Εικόνα 87*. Στο σημείο αυτό μπορούμε να φορτώσουμε τα κατάλληλα αρχεία και να ξεκινήσουμε το classification. Μετά την εισαγωγή των δεδομένων μας, οι υπόλοιπες καρτέλες γίνονται ενεργές προς χρήση.



Εικόνα 87: Η οθόνη του Explorer του περιβάλλοντος WEKA

- **Preprocess** : Από εδώ μπορούμε να έχουμε πρόσβαση στα αρχεία με τα υπό ταξινόμηση δεδομένα.
- **Classify** : Είναι το παράθυρο όπου εκτελούνται οι αλγόριθμοι ταξινόμησης και φαίνονται τα αποτελέσματα.
- **Cluster** : Με την επιλογή αυτή μπορούμε να ομαδοποιήσουμε τα δεδομένα σε συστοιχίες.
- **Visualize** : Στην καρτέλα αυτή γίνεται οπτικοποίηση με διάφορες μορφές.

### Preprocessing

Όπως είπαμε, στην καρτέλα αυτή φορτώνεται το αρχείο το οποίο θα υποστεί επεξεργασία. Το αρχείο πρέπει να έχει συγκεκριμένο format, και έχει κατάλληλη arff. Στην επόμενη παράγραφο περιγράφουμε αναλυτικά το συγκεκριμένο format. Υπάρχει δυνατότητα να φορτωθούν και άλλα format αρχείων, όπως csv, .arff, .names, .bsi και .data. Ιδιαίτερα τα csv είναι ένα σχήμα το οποίο έχει υιοθετηθεί από πολλές και διαφορετικές ετερόκλητες εταιρείες και εφαρμογές,



και είναι διαχειρίσιμο μέσα από λογισμικά επεξεργασίας λογιστικών φύλλων (π.χ. excel, calc κ.τ.λ.). Υπάρχουν δε εφαρμογές που δίνουν τη δυνατότητα στο χρήστη να μετατρέψει αρχεία από csv σε arff με αποτέλεσμα, όπως είναι προφανές, να καθίσταται ιδιαίτερα σημαντικό format.

Οι επιλογές της καρτέλας Preprocessing είναι :

- **Open File** : επιτρέπει στο χρήστη να επιλέξει τα αρχεία που είναι αποθηκευμένα στον τοπικό δίσκο.
- **Open URL** : παρέχει έναν μηχανισμό για να εντοπίσει μια πηγή αρχείων ή στοιχείων από μια διαφορετική θέση που διευκρινίζεται από το χρήστη.
- **Open Database** : επιτρέπει στο χρήστη να ανακτήσει τα αρχεία ή τα στοιχεία από μια πηγή βάσεων δεδομένων που παρέχεται από το χρήστη

Στην ίδια καρτέλα, υπάρχει η δυνατότητα να χρησιμοποιηθούν διάφορα φίλτρα για τη φόρτωση των δεδομένων. Επίσης υπάρχει η δυνατότητα για οπτικοποίηση των δεδομένων, όπως φαίνεται στις **Εικόνα 36** και **Εικόνα 37**.



## Παράρτημα Β

### ΜΕΤΑΣΧΗΜΑΤΙΣΜΟΣ FOURIER ΠΕΡΙΟΔΙΚΩΝ ΣΗΜΑΤΩΝ

Έστω το σήμα με μετασχηματισμό Fourier  $X(j\omega) = 2\pi\delta(\omega - \omega_0)$

$$\Rightarrow \text{Άρα } x(t) = 12\pi \int_{-\infty}^{\infty} (j\omega) e^{j\omega t} d\omega = 12\pi \int 2\pi\delta(\omega - \omega_0) e^{j\omega t} d\omega = e^{j\omega_0 t}.$$

➤ Στη γενική περίπτωση

$$X(j\omega) = \sum_{-\infty}^{\infty} 2\pi a_k \delta(\omega - k\omega_0) \Rightarrow x(t) = \sum_{-\infty}^{\infty} a_k e^{jk\omega_0 t}$$

➤ Άρα ο Μ.Φ. ενός περιοδικού σήματος  $x(t)$  με αναπαράσταση σε σειρές Fourier

$x(t) \leftrightarrow \alpha_k$  είναι άθροισμα κρουστικών αποκρίσεων στα σημεία  $k\omega_0$  με επιφάνεια  $2\pi\alpha_k$ .

### Περιοδικά σήματα – Σειρές Fourier

$$x(t) = \sum_{-\infty}^{\infty} a_k e^{jk\omega_0 t} \\ \alpha_k = \frac{1}{T} \int_0^T x(t) e^{-jk\omega_0 t} dt.$$

### Απεριοδικά σήματα – Μετασχηματισμός Fourier:

$$x(t) = \int_{-\infty}^{\infty} X(j\omega) e^{j\omega t} d\omega \\ X(j\omega) = \int_{-\infty}^{\infty} x(t) e^{-j\omega t} dt$$

Μετασχηματισμός Fourier για περιοδικά σήματα:

$$X(j\omega) = 2\pi \sum_{-\infty}^{\infty} a_k \delta(\omega - k\omega_0)$$

### ΙΔΙΟΤΗΤΕΣ ΜΕΤΑΣΧΗΜΑΤΙΣΜΟΥ FOURIER (DTFT)

#### Γραμμικότητα

Ο Μετασχηματισμός Fourier Διακριτού Χρόνου είναι ένας γραμμικός τελεστής. Αν  $X_1(e^{j\omega})$  είναι ο DTFT της  $x_1(n)$  και  $X_2(e^{j\omega})$  ο DTFT της  $x_2(n)$ , τότε είναι:

$$ax_1(n) + bx_2(n) \leftrightarrow aX_1(e^{j\omega}) + bX_2(e^{j\omega})$$

#### Μετατόπιση

Η μετατόπιση μιας ακολουθίας στο χρόνο έχει σαν αποτέλεσμα τον πολλαπλασιασμό του DTFT με ένα μιγαδικό εκθετικό όρο:

$$x(n-n_0) \leftrightarrow e^{-jn_0\omega} X(e^{j\omega})$$

### Αντιστροφή στο χρόνο

Η αντιστροφή στο χρόνο μιας ακολουθίας έχει ως αποτέλεσμα την αντιστροφή στη συχνότητα του DTFT

$$x(-n) \leftrightarrow X(e^{-j\omega})$$

### Διαμόρφωση

Πολλαπλασιάζοντας μια ακολουθία με ένα μιγαδικό εκθετικό όρο, έχουμε ως αποτέλεσμα μια μετατόπιση στη συχνότητα του DTFT:

$$e^{jn\omega_0} x(n) \leftrightarrow X(e^{j(\omega-\omega_0)})$$

Έτσι, η διαμόρφωση μιας ακολουθίας με ένα σήμα συνημιτόνου στη συχνότητα  $\omega_0$ , μετατοπίζει κατά  $\omega_0$  το φάσμα στη συχνότητα:

$$x(n) \cos n\omega_0 \leftrightarrow \frac{1}{2} X(e^{j(\omega-\omega_0)}) + \frac{1}{2} X(e^{j(\omega+\omega_0)})$$

### Το θεώρημα της Συνέλιξης

Η Συνέλιξη στο πεδίο του χρόνου ισοδυναμεί με την πράξη του πολλαπλασιασμού στο πεδίο της συχνότητας. Ειδικότερα, το θεώρημα αυτό λέει ότι ο DTFT μιας ακολουθίας η οποία 17 σχηματίζεται από δύο ακολουθίες,  $x(n)$  και  $h(n)$ , είναι το γινόμενο των DTFT των ακολουθιών  $x(n)$  και  $h(n)$ :

$$x(n) * h(n) \leftrightarrow H(e^{j\omega}) X(e^{j\omega})$$

### Το Θεώρημα του Parseval

Το Θεώρημα του Parseval δηλώνει ότι ο τελεστής DTFT διατηρεί την συνολική ενέργεια κατά την μετάβαση από το πεδίο του χρόνου στο πεδίο της συχνότητας.

$$\sum_{n=-\infty}^{\infty} |x(n)|^2 = \frac{1}{2\pi} \int_{-\pi}^{\pi} |X(e^{j\omega})|^2 d\omega$$

