

Μη-Γραμμική Ανάλυση  
Ηλεκτροεγκεφαλογραφικών Σημάτων Και  
Ταξινόμηση Γνωστικού Φορτίου με Χρήση  
Μηχανικής Μάθησης

Η Μεταπτυχιακή Εργασία Εξειδίκευσης

υποβάλλεται στην ορισθείσα

από την Συνέλευση

του Τμήματος Μηχανικών Η/Υ και Πληροφορικής

Εξεταστική Επιτροπή

από τον

Δημήτριο Κυρομίτη

ως μέρος των υποχρεώσεων για την απόκτηση του

ΜΕΤΑΠΤΥΧΙΑΚΟΥ ΔΙΠΛΩΜΑΤΟΣ ΕΙΔΙΚΕΥΣΗΣ

ΣΤΗΝ ΠΛΗΡΟΦΟΡΙΚΗ

ΜΕ ΕΞΕΙΔΙΚΕΥΣΗ

ΣΤΗ ΘΕΩΡΙΑ ΕΠΙΣΤΗΜΗΣ ΥΠΟΛΟΓΙΣΤΩΝ

Πανεπιστήμιο Ιωαννίνων

Φεβρουάριος 2026

Εξεταστική Επιτροπή:

- **Γεώργιος Μανής**, Αναπλ. Καθηγητής, Τμήμα Μηχανικών Η/Υ και Πληροφορικής, Πανεπιστήμιο Ιωαννίνων (Επιβλέπων)
- **Κόντης Λυσίμαχος-Παύλος**, Καθηγητής, Τμήμα Μηχανικών Η/Υ και Πληροφορικής, Πανεπιστήμιο Ιωαννίνων
- **Τσάμης Κωνσταντίνος**, Επικ. Καθηγητής, Τμήμα Ιατρικής, Πανεπιστήμιο Ιωαννίνων

# ΑΦΙΕΡΩΣΗ

---

Στην Μαργώ.

# ΕΥΧΑΡΙΣΤΙΕΣ

---

Θα ήθελα να εκφράσω τις θερμές μου ευχαριστίες στον επιβλέποντα καθηγητή Μανή Γεώργιο για την καθοδήγηση, την επιστημονική υποστήριξη και τις ουσιαστικές παρατηρήσεις του καθ' όλη τη διάρκεια της εκπόνησης της παρούσας διπλωματικής εργασίας. Η συμβολή του υπήρξε καθοριστική στη διαμόρφωση του ερευνητικού πλαισίου, στη μεθοδολογική προσέγγιση και στην ολοκλήρωση της εργασίας.

Ιδιαίτερες ευχαριστίες οφείλω στην οικογένειά μου για τη διαρκή στήριξη, την κατανόηση και την ενθάρρυνση σε όλη τη διάρκεια των σπουδών μου.

Τέλος, θα ήθελα να ευχαριστήσω την κοπέλα μου για την υπομονή, την ψυχολογική στήριξη και τη συνεχή ενθάρρυνση που μου προσέφερε, συμβάλλοντας ουσιαστικά στην ολοκλήρωση της παρούσας εργασίας.

# ΠΕΡΙΕΧΟΜΕΝΑ

---

Κατάλογος Σχημάτων	v
Κατάλογος Πινάκων	vi
Περίληψη	vii
Κατάλογος Αλγορίθμων	vii
Extended Abstract	ix
<b>1 Εισαγωγή</b>	<b>1</b>
1.1 Ηλεκτροεγκεφαλογραφία και Ανάλυση Εγκεφαλικής Δραστηριότητας .	2
1.2 Κίνητρο και Στόχοι της Παρούσας Εργασίας . . . . .	3
1.3 Δομή και Συνεισφορά της Προτεινόμενης Προσέγγισης . . . . .	4
<b>2 Ιατρικό και Νευροεπιστημονικό Υπόβαθρο</b>	<b>6</b>
2.1 Τι είναι και τι (δεν) μετρά το EEG . . . . .	7
2.2 Γνωστικός φόρτος και νοητική αριθμητική ως πειραματικό παράδειγμα	9
2.3 Ποιότητα σήματος, μεταβλητότητα και μεθοδολογική εγκυρότητα . . .	10
2.4 Σύνδεση με τη μεθοδολογία της παρούσας εργασίας . . . . .	11
<b>3 Σχετικές Ερευνες</b>	<b>13</b>
3.1 Task paradigms και φυσιολογική τεκμηρίωση του mental arithmetic . .	14
3.2 Φασματικά και χρονοφασματικά χαρακτηριστικά: από PSD σε data-driven ζώνες . . . . .	15
3.3 Nonlinear/dynamic χαρακτηριστικά: entropy και recurrence-based ανα- παραστάσεις . . . . .	15
3.4 Deep learning και <i>end-to-end</i> pipelines για mental workload/mental arithmetic . . . . .	16

3.5	Πρωτόκολλα αξιολόγησης, cross-subject γενίκευση και κίνδυνοι leakage	16
3.6	Σχέση με BCI βιβλιογραφία και μεταφορά μεθοδολογικών συμπερασμάτων . . . . .	17
3.7	Σύνθεση κενών και κατεύθυνση προς την παρούσα μεθοδολογία . . . .	17
<b>4</b>	<b>Από τη Βιβλιογραφία στο Pipeline: Αναπαράσταση, Μη-Γραμμικά Χαρακτηριστικά και Έγκυρη Αξιολόγηση</b>	<b>19</b>
4.1	Αναπαράσταση πριν από RQA: γιατί ο “χώρος καταστάσεων” είναι το πραγματικό σημείο-κλειδί . . . . .	20
4.2	Μη-γραμμικά χαρακτηριστικά και LOSO: όταν η δυναμική πληροφορία πρέπει να επιβιώσει σε νέο υποκείμενο . . . . .	23
4.3	Η αξιολόγηση ως επιστημονική δέσμευση: leakage, subject-wise split και nested επιλογές . . . . .	24
4.4	Cross-subject γενίκευση ως distribution shift: γιατί η σταθερότητα χαρακτηριστικών είναι στόχος σχεδιασμού . . . . .	25
4.5	Κλασικό baseline mental arithmetic: τι κερδίζουμε και τι χάνουμε με fixed-band/γραμμικές προσεγγίσεις . . . . .	26
4.6	Συνθετική αποτίμηση: γιατί η βιβλιογραφία συγκλίνει σε Αναπαράσταση + RQA + LOSO . . . . .	27
<b>5</b>	<b>Θεωρητικό Υπόβαθρο</b>	<b>29</b>
5.1	EEG Σήματα . . . . .	30
5.1.1	Ιδιότητες EEG σημάτων και επιπτώσεις στην ανάλυση . . . . .	30
5.2	Κλασική Φασματική Ανάλυση EEG και περιορισμοί . . . . .	31
5.3	Μη-Γραμμική θεώρηση και δυναμικά συστήματα . . . . .	32
5.4	Ανακατασκευή χώρου φάσεων (Phase-Space Reconstruction) . . . . .	33
5.4.1	Θεώρημα Takens και σημασία για EEG . . . . .	33
5.4.2	Παράμετροι $\tau$ και $m$ . . . . .	33
5.5	Recurrence Plots: από τη γεωμετρία στη δομή . . . . .	34
5.5.1	Ποιοτική ερμηνεία μορφών στο RP . . . . .	34
5.5.2	Η κρίσιμη επιλογή του $\epsilon$ . . . . .	35
5.6	Recurrence Quantification Analysis (RQA) . . . . .	35
5.6.1	RQA με απλά λόγια: τι μετράει και γιατί έχει νόημα . . . . .	35
5.6.2	Τυπικοί ορισμοί: γραμμές, κατανομές και μετρικές . . . . .	36
5.6.3	Βασικές και συμπληρωματικές μετρικές RQA . . . . .	36

5.6.4	Παράμετροι RQA και πρακτική σταθερότητα . . . . .	37
5.6.5	Windowed RQA: αποτύπωση μη-στασιμότητας . . . . .	37
5.7	Σχέση RQA, δυναμικής και γνωστικών διεργασιών . . . . .	39
5.8	Σύνοψη και σύνδεση με τη μεθοδολογία . . . . .	39
<b>6</b>	<b>Σύνολο Δεδομένων και Μεθοδολογία</b>	<b>41</b>
6.1	Σύνολο δεδομένων και πειραματικό πρωτόκολλο . . . . .	42
6.1.1	Πληθυσμός και ομάδες . . . . .	43
6.1.2	Συνθήκες καταγραφής και ηλεκτρόδια . . . . .	43
6.1.3	Διαθέσιμα τμήματα EEG ανά συμμετέχοντα . . . . .	43
6.2	Προεπεξεργασία και οργάνωση δεδομένων . . . . .	44
6.3	Ανακάλυψη/επιλογή ζωνών συχνοτήτων και φιλτράρισμα . . . . .	45
6.4	Εξαγωγή μη-γραμμικών χαρακτηριστικών με RQA . . . . .	46
6.5	Σύντηξη χαρακτηριστικών και ταξινόμηση . . . . .	46
6.5.1	Μετρικές αξιολόγησης . . . . .	47
6.6	Υλοποίηση και αναπαραγωγιμότητα . . . . .	47
<b>7</b>	<b>Υλοποίηση και Αναπαραγωγιμότητα</b>	<b>48</b>
7.1	Επισκόπηση της υπολογιστικής ροής (pipeline) . . . . .	48
7.2	Δομή κώδικα και ρόλοι αρχείων . . . . .	51
7.2.1	Κεντρικός ενορχηστρωτής: <code>run_pipeline.py</code> . . . . .	51
7.2.2	Φόρτωση δεδομένων: <code>load_data.py</code> . . . . .	51
7.2.3	Προεπεξεργασία: <code>preprocessing.py</code> . . . . .	51
7.2.4	Ανακάλυψη ζωνών συχνοτήτων: <code>band_discovery.py</code> . . . . .	52
7.2.5	Φιλτράρισμα ανά band: <code>filter_band.py</code> . . . . .	52
7.3	Εξαγωγή χαρακτηριστικών . . . . .	53
7.3.1	RQA: <code>utils_rqa.py</code> και <code>extract_rqa.py</code> . . . . .	53
7.3.2	Bubble Entropy: <code>bubble_entropy.py</code> . . . . .	53
7.4	Σύντηξη χαρακτηριστικών: <code>fuse_features.py</code> . . . . .	54
7.5	Εκπαίδευση και αξιολόγηση ταξινομητή: <code>train_classifier.py</code> . . . . .	54
<b>8</b>	<b>Αποτελέσματα και Συζήτηση</b>	<b>56</b>
8.1	Πειραματικό πρωτόκολλο αξιολόγησης . . . . .	57
8.2	Αποτελέσματα LOSO . . . . .	58
8.3	Ερμηνεία της μεμονωμένης αποτυχίας . . . . .	58

8.4	Συμπληρωματικά αποτελέσματα cross-validation . . . . .	59
8.5	Γιατί παρατηρούνται τόσο υψηλά ποσοστά . . . . .	60
8.6	Ποιοτική ερμηνεία μέσω recurrence plots . . . . .	61
8.7	Συζήτηση και περιορισμοί . . . . .	62
<b>9</b>	<b>Συμπεράσματα και Μελλοντική Εργασία</b>	<b>63</b>
9.1	Συμπεράσματα . . . . .	63
9.2	Περιορισμοί . . . . .	65
9.3	Μελλοντική εργασία . . . . .	66
	<b>Βιβλιογραφία</b>	<b>69</b>
<b>A</b>	<b>Λεπτομέρειες Υλοποίησης και Παραμετροποίησης Pipeline</b>	<b>73</b>
A.1	Παράμετροι προεπεξεργασίας . . . . .	73
A.2	Παράμετροι ανακάλυψης ζωνών συχνότητας . . . . .	74
A.3	Παράμετροι Recurrence Quantification Analysis . . . . .	74
A.4	Δομή διανύσματος χαρακτηριστικών . . . . .	75
A.5	Αποθηκευμένα artifacts και αναπαραγωγιμότητα . . . . .	75

# ΚΑΤΑΛΟΓΟΣ ΣΧΗΜΑΤΩΝ

---

7.1	Συνολική ροή του προτεινόμενου υπολογιστικού pipeline για ανάλυση και ταξινόμηση EEG σημάτων. Τα σήματα προεπεξεργάζονται, αποσυντίθενται σε ζώνες συχνότητων (κλασικές ή/και δεδομενοκεντρικές), αναλύονται μέσω μη-γραμμικών δεικτών (RQA και Bubble Entropy), συντίθενται σε ενιαία αναπαράσταση και αξιολογούνται με subject-wise πρωτόκολλα. . . . .	50
-----	---	----

# ΚΑΤΑΛΟΓΟΣ ΠΙΝΑΚΩΝ

---

5.1	Ενδεικτικές μετρικές Recurrence Quantification Analysis (RQA) και ερμηνεία τους. . . . .	38
-----	---	----

# ΠΕΡΙΛΗΨΗ

---

Δημήτριος Κυρομίτης, Μ.Δ.Ε. στην Πληροφορική, Τμήμα Μηχανικών Η/Υ και Πληροφορικής, Πανεπιστήμιο Ιωαννίνων, Φεβρουάριος 2026.

Μη-Γραμμική Ανάλυση Ηλεκτροεγκεφαλογραφικών Σημάτων Και Ταξινόμηση Γνωστικού Φορτίου με Χρήση Μηχανικής Μάθησης.

Επιβλέπων: Γεώργιος Μανής, Αναπληρωτής Καθηγητής.

Η ανάλυση ηλεκτροεγκεφαλογραφικών (EEG) σημάτων αποτελεί ένα ιδιαίτερα απαιτητικό πρόβλημα, λόγω της έντονης μη-στασιμότητας, της μη-γραμμικής δυναμικής και του χαμηλού λόγου σήματος προς θόρυβο που τα χαρακτηρίζει. Ιδιαίτερο ενδιαφέρον παρουσιάζει η διάκριση γνωστικών καταστάσεων διαφορετικού φορτίου, όπως η κατάσταση ηρεμίας και η εκτέλεση νοητικής αριθμητικής, καθώς σχετίζεται άμεσα με θεμελιώδεις εγκεφαλικές διεργασίες και εφαρμογές στη γνωσιακή νευροεπιστήμη.

Στην παρούσα μεταπτυχιακή διπλωματική εργασία προτείνεται και αξιολογείται ένα ολοκληρωμένο υπολογιστικό pipeline για την ανάλυση και ταξινόμηση EEG σημάτων, βασισμένο στη μη-γραμμική περιγραφή της δυναμικής τους μέσω Recurrence Quantification Analysis (RQA). Η μεθοδολογία συνδυάζει προεπεξεργασία και οργάνωση των δεδομένων, φασματική αποσύνθεση σε κλασικές ή/και δεδομενοκεντρικές ζώνες συχνοτήτων, εξαγωγή μη-γραμμικών χαρακτηριστικών RQA (Recurrence Rate, Determinism, Laminarity, Entropy) και σύντηξη χαρακτηριστικών σε ενιαία αναπαράσταση για επιβλεπόμενη μηχανική μάθηση.

Η αξιολόγηση πραγματοποιείται στο δημόσια διαθέσιμο σύνολο δεδομένων EEG-MAT, το οποίο περιλαμβάνει καταγραφές κατάστασης ηρεμίας και νοητικής αριθμητικής, με αυστηρό subject-wise πρωτόκολλο leave-one-subject-out. Τα πειραματικά αποτελέσματα δείχνουν πολύ υψηλή απόδοση στη διάκριση των δύο γνωστικών καταστάσεων, με μέση ακρίβεια 0.986, αναδεικνύοντας τη διακριτική ικανότητα των μη-γραμμικών χαρακτηριστικών. Παράλληλα, η ποιοτική ανάλυση μέσω recurrence

plots υποστηρίζει τα ποσοτικά ευρήματα, καθιστώντας ορατές τις δομικές διαφοροποιήσεις στη δυναμική οργάνωση του EEG.

Συνολικά, η εργασία τεκμηριώνει ότι η Recurrence Quantification Analysis, όταν ενσωματώνεται σε ένα αναπαραγώγιμο και συστηματικά σχεδιασμένο pipeline, αποτελεί ένα ισχυρό και ερμηνεύσιμο εργαλείο για την ανάλυση EEG σημάτων σε σενάρια γνωστικού φορτίου, ανοίγοντας τον δρόμο για περαιτέρω έρευνα και εφαρμογές σε πιο σύνθετα βιοϊατρικά πλαίσια.

# EXTENDED ABSTRACT

---

Dimitrios Kiromitis, M.Sc. in Computer Science, Department of Computer Science and Engineering, University of Ioannina, Greece, February 2026.

Nonlinear Analysis of Electroencephalographic Signals and Cognitive Load Classification Using Machine Learning.

Advisor: Georgios Manis, Associate Professor.

Electroencephalogram (EEG) signal analysis remains a challenging research problem due to the intrinsic non-stationarity, nonlinear dynamics, high inter-subject variability, and low signal-to-noise ratio of brain activity recordings. These properties limit the effectiveness of traditional linear and stationary analysis methods, particularly in scenarios where changes in cognitive state need to be captured reliably. A representative and widely studied problem in this context is the discrimination between cognitive states of different mental workload, such as resting state and mental arithmetic, which reflects fundamental mechanisms of neural organization and cognitive control.

Mental arithmetic induces increased cognitive load, attention, and executive function engagement, whereas resting state—especially with eyes closed—is typically associated with more regular and stable neural dynamics. As a result, the two conditions are expected to exhibit distinct temporal and dynamical properties in EEG recordings. However, capturing these differences in a way that generalizes across subjects remains non-trivial, particularly when the number of available subjects is limited.

This thesis proposes and evaluates a complete computational pipeline for EEG analysis and classification that explicitly targets the nonlinear and dynamic nature of EEG signals through Recurrence Quantification Analysis (RQA). Instead of relying solely on spectral power or stationary assumptions, the proposed approach focuses on characterizing the temporal organization and recurrence structure of EEG dynamics, which are sensitive to changes in cognitive state.

## Methodological Framework

The proposed pipeline is designed with an emphasis on modularity, reproducibility, and strict evaluation. It consists of data loading and organization on a subject-wise basis, basic preprocessing to ensure signal consistency, spectral decomposition into classical and/or data-driven frequency bands, extraction of nonlinear RQA features, feature fusion into a unified representation, and supervised classification.

RQA is based on phase-space reconstruction via time-delay embedding and the computation of recurrence plots, which encode when the system revisits similar states. From these plots, quantitative measures such as Recurrence Rate (RR), Determinism (DET), Laminarity (LAM), and Entropy (ENTR) are extracted, capturing complementary aspects of signal dynamics including regularity, predictability, laminar behavior, and complexity.

## Evaluation Protocol

A key design choice of this work is the adoption of a strict subject-wise evaluation strategy. EEG data exhibit strong inter-subject variability, and sample-wise validation often leads to overly optimistic performance estimates. To address this issue, the primary evaluation is conducted using a leave-one-subject-out (LOSO) protocol, where each fold tests the model on an unseen subject while the remaining subjects form the training set.

Given that each subject contributes one resting-state and one mental arithmetic sample, the test set per fold consists of only two samples, leading to coarse fold-level accuracies and increased variability. For completeness, a supplementary 5-fold cross-validation experiment is also performed, offering an additional perspective under less strict validation conditions.

## Experimental Results

The proposed pipeline is evaluated on the publicly available EEGMAT dataset, which includes EEG recordings of resting state and mental arithmetic from multiple subjects. Under the LOSO protocol, the method achieves a mean classification accuracy of 0.986, with correct classification in the vast majority of folds. Only a single fold exhibits reduced performance due to the misclassification of one out of two test sam-

ples.

These results suggest that nonlinear RQA features capture highly discriminative information related to cognitive workload, even under stringent subject-wise evaluation. The complementary 5-fold cross-validation experiment yields similarly high performance with lower variance, as expected due to larger test sets per fold.

## **Qualitative Analysis and Interpretability**

Beyond quantitative metrics, the thesis includes a qualitative analysis using recurrence plots to visualize differences in EEG dynamics between cognitive states. Representative plots indicate that resting-state EEG exhibits denser and more organized recurrence structures, reflecting higher regularity and stability, whereas mental arithmetic is associated with sparser and less structured patterns, consistent with increased dynamical complexity.

These visual observations are aligned with the behavior of RQA metrics and support the interpretation that the classifier exploits meaningful differences in signal dynamics. The recurrence plots are presented as illustrative tools, computed on representative signal segments and with visualization-oriented parameter choices, while quantitative features are extracted using the full pipeline.

## **Discussion and Limitations**

The results demonstrate that RQA provides a powerful and interpretable framework for EEG-based cognitive state discrimination when embedded in a reproducible pipeline and evaluated under strict subject-wise protocols. Nevertheless, several limitations should be acknowledged. The number of subjects is limited, constraining statistical resolution, and the study focuses on a binary problem with a clear contrast between cognitive states. More subtle distinctions may require additional data and more complex modeling strategies.

## **Conclusion**

In summary, this thesis presents a systematically designed computational pipeline for EEG analysis that leverages Recurrence Quantification Analysis to capture nonlinear and non-stationary brain dynamics. The experimental results on the EEGMAT

dataset indicate that RQA-based features can effectively discriminate between resting state and mental arithmetic under strict subject-wise evaluation, while offering interpretability through both quantitative metrics and qualitative visualizations. The proposed approach provides a solid foundation for future research on EEG-based cognitive workload analysis and related applications.

# ΚΕΦΑΛΑΙΟ 1

## ΕΙΣΑΓΩΓΗ

---

1.1 Ηλεκτροεγκεφαλογραφία και Ανάλυση Εγκεφαλικής Δραστηριότητας

1.2 Κίνητρο και Στόχοι της Παρούσας Εργασίας

1.3 Δομή και Συνεισφορά της Προτεινόμενης Προσέγγισης

---

Η ανάλυση ηλεκτροεγκεφαλογραφικών (ΗΕΓ/ΕΕΓ) σημάτων αποτελεί ένα από τα πλέον ενεργά και απαιτητικά ερευνητικά πεδία στη διασταύρωση της γνωσιακής νευροεπιστήμης, της επεξεργασίας σήματος και της μηχανικής μάθησης. Παρά τη διευρυμένη χρήση του ΕΕΓ ως μη επεμβατικού μέσου καταγραφής εγκεφαλικής δραστηριότητας, η εξαγωγή αξιόπιστης και γενικεύσιμης πληροφορίας παραμένει ιδιαίτερα δύσκολη. Τα ΕΕΓ σήματα χαρακτηρίζονται από έντονη μη-στασιμότητα, μη-γραμμική δυναμική, χαμηλό λόγο σήματος προς θόρυβο, φαινόμενα αγωγής όγκου (volume conduction) και υψηλή δια-υποκειμενική μεταβλητότητα. Οι ιδιότητες αυτές δεν αποτελούν απλώς τεχνικές δυσκολίες, αλλά εγγενή χαρακτηριστικά της εγκεφαλικής λειτουργίας, τα οποία περιορίζουν την αποτελεσματικότητα κλασικών γραμμικών και στάσιμων προσεγγίσεων, ιδίως σε σενάρια όπου απαιτείται αξιόπιστη ανίχνευση μεταβολών στη γνωστική κατάσταση.

Ένα χαρακτηριστικό και ευρέως μελετημένο πρόβλημα σε αυτό το πλαίσιο είναι η διάκριση μεταξύ καταστάσεων διαφορετικού γνωστικού φορτίου, όπως η κατάσταση ηρεμίας (resting state) και η εκτέλεση νοητικής αριθμητικής (mental arithmetic). Η νοητική αριθμητική ενεργοποιεί μηχανισμούς προσοχής, μνήμης εργασίας

και εκτελεστικού ελέγχου, οδηγώντας σε αυξημένο γνωστικό φορτίο και, κατ' επέκταση, σε μεταβολές όχι μόνο στο φασματικό περιεχόμενο, αλλά και στη χρονική οργάνωση και στη δυναμική δομή της εγκεφαλικής δραστηριότητας. Αντίθετα, η κατάσταση ηρεμίας, ιδίως με κλειστά μάτια, συνδέεται συχνά με πιο σταθερά και επαναλαμβανόμενα πρότυπα δραστηριότητας. Ωστόσο, η αποτύπωση αυτών των διαφορών με τρόπο που να γενικεύει σε νέους συμμετέχοντες δεν είναι τετριμμένη, ιδιαίτερα όταν ο αριθμός των διαθέσιμων υποκειμένων είναι περιορισμένος και η δια-υποκειμενική μεταβλητότητα έντονη.

Στο πλαίσιο της παρούσας μεταπτυχιακής διπλωματικής, η ανάλυση του EEG προσεγγίζεται όχι μόνο ως βιοϊατρικό πρόβλημα, αλλά και ως πρόβλημα σχεδίασης ενός ολοκληρωμένου και μεθοδολογικά αυστηρού υπολογιστικού pipeline για μη-στάσιμα και μη-γραμμικά δεδομένα. Κεντρική θέση της εργασίας είναι ότι η επιλογή αναπαράστασης και χαρακτηριστικών προηγείται της επιλογής του ταξινομητή και καθορίζει σε μεγάλο βαθμό τόσο την απόδοση όσο και τη δυνατότητα γενίκευσης του μοντέλου.

## **1.1 Ηλεκτροεγκεφαλογραφία και Ανάλυση Εγκεφαλικής Δραστηριότητας**

Η ηλεκτροεγκεφαλογραφία (Electroencephalography – EEG) αποτελεί μία από τις πλέον διαδεδομένες και μη επεμβατικές τεχνικές καταγραφής της ηλεκτρικής δραστηριότητας του εγκεφάλου. Μέσω της καταγραφής διαφορών δυναμικού στην επιφάνεια του κρανίου, οι οποίες προκύπτουν από τη συγχρονισμένη δραστηριότητα πληθυσμών πυραμιδικών νευρώνων στον εγκεφαλικό φλοιό, το EEG παρέχει πληροφορία υψηλής χρονικής ανάλυσης σχετικά με εγκεφαλικές διεργασίες που σχετίζονται με γνωστικές λειτουργίες, αισθητηριακή επεξεργασία και εκούσια δράση. Η ιδιότητα αυτή καθιστά το EEG ιδιαίτερα ελκυστικό τόσο για κλινικές εφαρμογές όσο και για ερευνητικές μελέτες στη γνωσιακή νευροεπιστήμη και στις διεπαφές εγκεφάλου-υπολογιστή (BCI).

Παρά τα πλεονεκτήματά του, το EEG χαρακτηρίζεται από σημαντική πολυπλοκότητα. Τα σήματα είναι χαμηλού πλάτους και έντονα θορυβώδη, επηρεάζονται από οφθαλμοκινητικά και μυϊκά artifacts, ενώ η αγωγή όγκου οδηγεί σε μίξη πηγών μεταξύ γειτονικών καναλιών. Επιπλέον, το EEG αποτελεί έκφραση ενός πολύπλοκου

δυναμικού συστήματος και, ως εκ τούτου, παρουσιάζει έντονη μη-γραμμικότητα και μη-στασιμότητα. Οι διαφορές μεταξύ γνωστικών καταστάσεων ενδέχεται να εκδηλώνονται όχι μόνο ως αλλαγές στη μέση ισχύ συγκεκριμένων συχνοτήτων, αλλά και ως μεταβολές στον τρόπο με τον οποίο η εγκεφαλική δραστηριότητα οργανώνεται και εξελίσσεται στον χρόνο.

Στη βιβλιογραφία, κυρίαρχες προσεγγίσεις βασίζονται σε φασματικές μετρικές ισχύος εντός προκαθορισμένων ζωνών συχνοτήτων ( $\delta$ ,  $\theta$ ,  $\alpha$ ,  $\beta$ ,  $\gamma$ ), καθώς και σε γραμμικές τεχνικές χωρικής φιλτραρίσματος. Παρότι οι μέθοδοι αυτές είναι σχετικά απλές και ερμηνεύσιμες, ενδέχεται να μην αποτυπώνουν πλήρως τη δυναμική οργάνωση του EEG, ιδίως όταν οι μεταβολές μεταξύ συνθηκών αφορούν τη δομή, την προβλεψιμότητα και την πολυπλοκότητα της χρονικής εξέλιξης. Για παράδειγμα, σε κατάσταση ηρεμίας η εγκεφαλική δραστηριότητα μπορεί να εμφανίζει πιο επαναλαμβανόμενα και σταθερά μοτίβα, ενώ κατά την εκτέλεση απαιτητικών νοητικών πράξεων η δυναμική γίνεται πιο ακανόνιστη και πολυδιάστατη, αντανακλώντας τη συνεχή προσαρμογή του νευρωνικού συστήματος στις γνωστικές απαιτήσεις.

Τα παραπάνω υποδεικνύουν ότι η κατανόηση των γνωστικών καταστάσεων δεν μπορεί να βασίζεται αποκλειστικά σε στατικές ή μέσες περιγραφές της εγκεφαλικής δραστηριότητας, αλλά απαιτεί μεθόδους που να αποτυπώνουν τη χρονική οργάνωση και τη μη-γραμμική δυναμική των σημάτων.

## 1.2 Κίνητρο και Στόχοι της Παρούσας Εργασίας

Το βασικό κίνητρο της παρούσας εργασίας έγκειται στην ανάγκη γεφύρωσης του χάσματος μεταξύ της πολύπλοκης δυναμικής φύσης του EEG και των συχνά απλουστευτικών γραμμικών προσεγγίσεων που κυριαρχούν στην πράξη. Υιοθετείται η άποψη ότι, προκειμένου να ανιχνευθούν αξιόπιστα μεταβολές που σχετίζονται με διαφορετικά επίπεδα γνωστικού φορτίου, είναι απαραίτητη μια αναπαράσταση του σήματος που να λαμβάνει υπόψη τόσο το φασματικό περιεχόμενο όσο και τη δομική/δυναμική του οργάνωση.

Η παρούσα εργασία εστιάζει στη διάκριση μεταξύ κατάστασης ηρεμίας και νοητικής αριθμητικής, χρησιμοποιώντας το δημόσια διαθέσιμο σύνολο δεδομένων EEG-MAT. Η επιλογή του συγκεκριμένου προβλήματος βασίζεται στο ότι αποτελεί καλά ορισμένο και αναπαραγώγιμο πειραματικό παράδειγμα γνωστικού φορτίου, ενώ

ταυτόχρονα αναδεικνύει τις δυσκολίες γενίκευσης σε δια-υποκειμενικό επίπεδο.

Κεντρικός στόχος της διπλωματικής είναι η ανάπτυξη και αξιολόγηση ενός ολοκληρωμένου υπολογιστικού pipeline το οποίο: ενσωματώνει προσαρμοστική (adaptive) φασματική αποσύνθεση, ώστε να μειωθεί η εξάρτηση από αυθαίρετα προκαθορισμένες ζώνες συχνοτήτων, αξιοποιεί τη Recurrence Quantification Analysis (RQA) για την ποσοτική περιγραφή της μη-γραμμικής δυναμικής των σημάτων, συνδυάζει φασματικά και μη-γραμμικά χαρακτηριστικά σε ενιαία αναπαράσταση, και αξιολογείται με αυστηρή στρατηγική leave-one-subject-out (LOSO), ώστε να προσεγγίζει ρεαλιστικά σενάρια εφαρμογής σε νέους χρήστες.

Η έμφαση στη subject-wise αξιολόγηση δεν αποτελεί απλώς τεχνική λεπτομέρεια, αλλά θεμελιώδη σχεδιαστική επιλογή. Δεδομένης της έντονης δια-υποκειμενικής μεταβλητότητας, ένα μοντέλο που αξιολογείται σε δεδομένα του ίδιου συμμετέχοντα μπορεί να εμφανίζει τεχνητά υψηλή απόδοση χωρίς να έχει πραγματικά μάθει γενικεύσιμα μοτίβα. Αντίθετα, το πρωτόκολλο LOSO επιβάλλει τη δοκιμή του μοντέλου σε πλήρως «αόρατο» υποκείμενο, ενισχύοντας τη μεθοδολογική εγκυρότητα των αποτελεσμάτων.

### 1.3 Δομή και Συνεισφορά της Προτεινόμενης Προσέγγισης

Η προτεινόμενη προσέγγιση οργανώνεται ως ένα συνεκτικό και αναπαραγωγίμο pipeline, στο οποίο κάθε στάδιο είναι σαφώς ορισμένο και αιτιολογημένο. Το pipeline περιλαμβάνει τη φόρτωση και οργάνωση των δεδομένων σε επίπεδο υποκειμένου, την προεπεξεργασία και κανονικοποίηση των σημάτων, την προσαρμοστική φασματική αποσύνθεση, την εξαγωγή μη-γραμμικών χαρακτηριστικών μέσω Recurrence Quantification Analysis, τη σύντηξη των χαρακτηριστικών σε ενιαίο διανυσματικό χώρο και, τέλος, την εκπαίδευση και αξιολόγηση επιβλεπόμενων μοντέλων μηχανικής μάθησης.

Ο πυρήνας της μεθοδολογίας είναι η Recurrence Quantification Analysis, η οποία επιτρέπει την ποσοτική περιγραφή της χρονικής οργάνωσης της δυναμικής μέσω μετρικών όπως το Recurrence Rate, ο Determinism, η Laminarity και η Entropy. Οι μετρικές αυτές αποτυπώνουν διαφορετικές όψεις της δομής και της προβλεψιμότητας του σήματος, παρέχοντας πληροφορία που δεν είναι εύκολα ανιχνεύσιμη με καθαρά φασματικές προσεγγίσεις. Παράλληλα, τα recurrence plots χρησιμοποιούνται

ως εργαλείο οπτικοποίησης, συμβάλλοντας στην ποιοτική ερμηνεία των διαφορών μεταξύ ηρεμίας και νοητικής αριθμητικής.

Συνολικά, η συμβολή της εργασίας έγκειται όχι μόνο στην εφαρμογή συγκεκριμένων μετρικών, αλλά κυρίως στη συστηματική σύνθεση βιβλιογραφικών ιδεών σε ένα ενιαίο, μεθοδολογικά αυστηρό πλαίσιο, όπου η αναπαράσταση, η μη-γραμμική δυναμική και η αξιολόγηση ανά υποκείμενο αντιμετωπίζονται ως αλληλένδετα και όχι ανεξάρτητα στάδια. Με τον τρόπο αυτό, η διάκριση μεταξύ κατάστασης ηρεμίας και νοητικής αριθμητικής δεν αντιμετωπίζεται απλώς ως πρόβλημα ταξινόμησης, αλλά ως πρόβλημα μοντελοποίησης και κατανόησης της εγκεφαλικής δυναμικής υπό διαφορετικό γνωστικό φορτίο.

## ΚΕΦΑΛΑΙΟ 2

# ΙΑΤΡΙΚΟ ΚΑΙ ΝΕΥΡΟΕΠΙΣΤΗΜΟΝΙΚΟ ΥΠΟΒΑΘΡΟ

---

2.1 Τι είναι και τι (δεν) μετρά το EEG

2.2 Γνωστικός φόρτος και νοητική αριθμητική ως πειραματικό παράδειγμα

2.3 Ποιότητα σήματος, μεταβλητότητα και μεθοδολογική εγκυρότητα

2.4 Σύνδεση με τη μεθοδολογία της παρούσας εργασίας

---

Η παρούσα μεταπτυχιακή εργασία εντάσσεται στο πεδίο της βιοϊατρικής ανάλυσης δεδομένων και της υπολογιστικής νευροεπιστήμης, με στόχο τη μελέτη της εγκεφαλικής λειτουργίας μέσω σημάτων ηλεκτροεγκεφαλογραφίας (EEG). Το EEG αποτελεί μία από τις πλέον καθιερωμένες και ευρέως χρησιμοποιούμενες μεθόδους καταγραφής εγκεφαλικής δραστηριότητας, τόσο σε ερευνητικά όσο και σε κλινικά περιβάλλοντα. Η εκτεταμένη χρήση του οφείλεται κυρίως σε τρία βασικά χαρακτηριστικά: (i) την εξαιρετικά υψηλή χρονική ανάλυση (της τάξης των milliseconds), (ii) τη μη-επεμβατική φύση της μεθόδου, και (iii) τη δυνατότητα καταγραφής δυναμικών μεταβολών της εγκεφαλικής λειτουργίας σε πραγματικό χρόνο.

Η υψηλή χρονική ανάλυση του EEG είναι ιδιαίτερα σημαντική σε προβλήματα όπου η γνωστική κατάσταση του ατόμου δεν είναι στατική, αλλά μεταβάλλεται γρήγορα και συχνά απρόβλεπτα. Παραδείγματα τέτοιων εφαρμογών περιλαμβάνουν συστήματα διεπαφής ανθρώπου-υπολογιστή (HCI), διεπαφές εγκεφάλου-υπολογιστή (BCI), καθώς και συστήματα παρακολούθησης ανθρώπινης απόδοσης σε απαιτητικά ή υψηλού κινδύνου περιβάλλοντα. Σε αυτά τα σενάρια, ακόμη και μικρές μεταβολές

στη συγκέντρωση, την κόπωση ή το γνωστικό φορτίο μπορούν να έχουν σημαντικές επιπτώσεις στη συνολική απόδοση ή ασφάλεια. Το EEG προσφέρει τη δυνατότητα ανίχνευσης τέτοιων μεταβάσεων με χρονική ακρίβεια που δεν είναι εφικτή με άλλες τεχνικές νευροαπεικόνισης, όπως η fMRI.

Παρά τα πλεονεκτήματά του, το EEG αποτελεί ταυτόχρονα ένα από τα πιο απαιτητικά σήματα από άποψη ανάλυσης. Ως μέτρο μακροσκοπικής νευρωνικής δραστηριότητας, ενσωματώνει τη συλλογική συμπεριφορά μεγάλων πληθυσμών νευρώνων και όχι τη δραστηριότητα μεμονωμένων κυττάρων. Αυτό συνεπάγεται περιορισμένη χωρική ανάλυση, έντονη ευαισθησία σε εξωγενείς παρεμβολές (artifacts), καθώς και σημαντική μη-στασιμότητα. Επιπλέον, οι εγκεφαλικές αποκρίσεις παρουσιάζουν μεγάλη δια-υποκειμενική μεταβλητότητα, γεγονός που καθιστά τη γενίκευση υπολογιστικών μοντέλων ιδιαίτερα δύσκολη. Οι ιδιότητες αυτές δεν αποτελούν απλώς τεχνικές δυσκολίες, αλλά αντικατοπτρίζουν θεμελιώδη βιολογικά και πειραματικά χαρακτηριστικά της εγκεφαλικής λειτουργίας.

Στο πλαίσιο αυτό, η παρούσα εργασία υιοθετεί το βιοϊατρικό υπόβαθρο όχι μόνο ως θεωρητική εισαγωγή, αλλά ως βάση για την αιτιολόγηση συγκεκριμένων μεθοδολογικών επιλογών. Ειδικότερα, η ανάγκη αντιμετώπισης της μη-στασιμότητας και της μεταβλητότητας οδηγεί στην επιλογή προσαρμοστικής (*adaptive*) φασματικής αναπαράστασης, ενώ η επιθυμία αποτύπωσης της χρονικής οργάνωσης της εγκεφαλικής δραστηριότητας θεμελιώνει τη χρήση μη-γραμμικών μεθόδων και ειδικότερα της Recurrence Quantification Analysis (RQA). Τέλος, η έμφαση στη ρεαλιστική γενίκευση καθιστά απαραίτητη την αυστηρή subject-wise αξιολόγηση (π.χ. Leave-One-Subject-Out), η οποία αντανακλά το σενάριο χρήσης σε νέο άτομο [1, 2, 3, 4, 5].

## 2.1 Τι είναι και τι (δεν) μετρά το EEG

Από νευροφυσιολογική σκοπιά, το EEG καταγράφει διαφορές ηλεκτρικού δυναμικού στην επιφάνεια του κρανίου. Οι διαφορές αυτές προκύπτουν από τη συλλογική δραστηριότητα μεγάλων πληθυσμών νευρώνων του εγκεφαλικού φλοιού. Η κλασική ερμηνεία αποδίδει το μεγαλύτερο μέρος του καταγραφόμενου σήματος στους πυραμιδικούς νευρώνες, οι οποίοι λόγω του επιμήκους προσανατολισμού τους και της ταυτόχρονης δενδριτικής ενεργοποίησης δημιουργούν ηλεκτρικά διπόλια. Όταν μεγάλος αριθμός τέτοιων νευρώνων ενεργοποιείται συγχρονισμένα, τα παραγόμενα

πεδία αθροίζονται και καθίστανται ανιχνεύσιμα από επιφανειακά ηλεκτρόδια.

Ένα κρίσιμο στοιχείο είναι ότι το EEG απαιτεί συγχρονισμό τόσο στον χρόνο όσο και στον χώρο. Μεμονωμένες νευρωνικές εκφορτίσεις, ακόμη και αν είναι ισχυρές, δεν επαρκούν για να παραχθεί σήμα μετρήσιμο στο κρανίο. Αντίθετα, απαιτείται συντονισμένη δραστηριότητα μεγάλων πληθυσμών, γεγονός που καθιστά το EEG εγγενώς *population-level* μέτρο. Αυτό έχει άμεσες συνέπειες στη βιολογική ερμηνεία των αποτελεσμάτων: οι διαφορές που παρατηρούνται στο EEG αντανακλούν αλλαγές στη συλλογική οργάνωση και όχι απαραίτητα αλλαγές στη δραστηριότητα συγκεκριμένων μικροσκοπικών δομών.

Ένα απλό παράδειγμα που βοηθά στην κατανόηση αυτής της ιδιότητας είναι το εξής: αν φανταστούμε ένα στάδιο γεμάτο θεατές, ένα άτομο που σηκώνεται και χειροκροτεί δεν είναι εύκολα αντιληπτό από μακριά. Αν όμως χιλιάδες θεατές αρχίσουν να χειροκροτούν ταυτόχρονα και με παρόμοιο ρυθμό, το φαινόμενο γίνεται σαφώς αντιληπτό. Αντίστοιχα, το EEG «βλέπει» τη συγχρονισμένη δραστηριότητα μεγάλων νευρωνικών πληθυσμών, αλλά όχι τη δράση μεμονωμένων νευρώνων.

Η παρατήρηση αυτή είναι ιδιαίτερα σημαντική όταν το EEG χρησιμοποιείται για την αναγνώριση γνωστικών καταστάσεων. Για παράδειγμα, στη διάκριση *rest vs mental arithmetic*, δεν αναζητούμε απλώς αν ο εγκέφαλος «δουλεύει περισσότερο», αλλά πώς αναδιοργανώνεται η συλλογική δραστηριότητα των νευρωνικών δικτύων. Αυτή η αναδιοργάνωση μπορεί να εκδηλώνεται τόσο ως αλλαγή σε ρυθμικές συνιστώσες (π.χ. αύξηση ή μείωση ισχύος σε συγκεκριμένες ζώνες), όσο και ως αλλαγή στη χρονική δομή και προβλεψιμότητα της δυναμικής.

Ένα δεύτερο θεμελιώδες ζήτημα είναι η αγωγή όγκου (*volume conduction*). Τα ηλεκτρικά πεδία που παράγονται στον εγκέφαλο διαδίδονται μέσα από διαφορετικούς ιστούς με διαφορετικές αγώγιμες ιδιότητες, όπως το εγκεφαλονωτιαίο υγρό, το κρανίο και το δέρμα. Ως αποτέλεσμα, το σήμα που καταγράφεται σε κάθε ηλεκτρόδιο αποτελεί μείγμα συνεισφορών από πολλαπλές πηγές. Αυτό περιορίζει την ακρίβεια χωρικής τοπικοποίησης και σημαίνει ότι οι πληροφορίες δεν είναι πλήρως ανεξάρτητες μεταξύ γειτονικών καναλιών.

Στην πράξη, η αγωγή όγκου επιβάλλει μια πιο προσεκτική και συστημική ερμηνεία των χωρικών μοτίβων. Αντί να αποδίδονται αλλαγές σε μεμονωμένα ηλεκτρόδια, είναι συχνά πιο ασφαλές να μιλάμε για περιοχές ενδιαφέροντος ή λειτουργικά δίκτυα. Για την παρούσα εργασία, αυτό σημαίνει ότι η ανάλυση επικεντρώνεται

περισσότερο στη δυναμική συμπεριφορά και λιγότερο σε αυστηρές χωρικές τοποποιήσεις.

## 2.2 Γνωστικός φόρτος και νοητική αριθμητική ως πειραματικό παράδειγμα

Ο γνωστικός φόρτος (*mental workload*) αναφέρεται στο επίπεδο γνωστικών πόρων που απαιτούνται για την εκτέλεση ενός έργου. Στη γνωστική νευροεπιστήμη, ο φόρτος δεν θεωρείται μία απλή ή μονοδιάστατη μεταβλητή, αλλά το αποτέλεσμα αλληλεπίδρασης πολλαπλών διεργασιών, όπως η μνήμη εργασίας, ο εκτελεστικός έλεγχος, η προσοχή και η παρακολούθηση λαθών. Όταν οι απαιτήσεις ενός έργου αυξάνονται, ο εγκέφαλος καλείται να αναδιοργανώσει τη λειτουργία του ώστε να ανταποκριθεί αποτελεσματικά.

Η νοητική αριθμητική (*mental arithmetic*) αποτελεί ένα από τα πιο διαδεδομένα πειραματικά παραδείγματα πρόκλησης γνωστικού φόρτου. Η ευρεία χρήση της οφείλεται στο ότι είναι εύκολα ορίσιμη, επαναλήψιμη και επιδέχεται κλιμάκωση δυσκολίας με απλούς τρόπους (π.χ. αλλαγή πράξης, αριθμού ψηφίων, ρυθμού παρουσίας ή διάρκειας). Επιπλέον, επειδή δεν απαιτεί έντονη αισθητηριακή επεξεργασία, θεωρείται σχετικά «καθαρό» πρωτόκολλο, εστιάζοντας κυρίως σε εσωτερικές γνωστικές διεργασίες [6].

Ωστόσο, ακόμη και σε αυτό το φαινομενικά απλό πλαίσιο, η γνωστική εμπειρία μπορεί να διαφέρει σημαντικά μεταξύ συμμετεχόντων. Διαφορές σε μαθηματική εξοικείωση, στρατηγικές επίλυσης, επίπεδο άγχους ή κόπωσης μπορούν να επηρεάσουν τόσο τη συμπεριφορά όσο και τη νευρωνική απόκριση. Αυτό σημαίνει ότι δύο άτομα μπορεί να εκτελούν το ίδιο πείραμα αλλά να παρουσιάζουν διαφορετικές νευρωνικές «υπογραφές», γεγονός που καθιστά τη γενίκευση υπολογιστικών μοντέλων μη τετριμμένη.

Σε επίπεδο λειτουργικών δικτύων, πολυάριθμες μελέτες δείχνουν ότι το *mental arithmetic* συνδέεται με συστηματική εμπλοκή μετωπιακών και βρεγματικών περιοχών, οι οποίες σχετίζονται με μνήμη εργασίας και γνωστικό έλεγχο. Αντίθετα, η κατάσταση ηρεμίας συχνά συνδέεται με αυξημένη δραστηριότητα δικτύων *baseline* λειτουργίας, όπως το *Default Mode Network*. Αυτή η διαφοροποίηση παρέχει

ένα χρήσιμο βιολογικό υπόβαθρο για την ερμηνεία των αποτελεσμάτων, χωρίς όμως να αναιρεί τη δυσκολία της υπολογιστικής αναγνώρισης σε επίπεδο μεμονωμένου ατόμου [7, 6].

### 2.3 Ποιότητα σήματος, μεταβλητότητα και μεθοδολογική εγκυρότητα

Η ποιότητα του σήματος αποτελεί θεμελιώδη παράγοντα σε κάθε ανάλυση EEG, καθώς το καταγραφόμενο σήμα δεν προέρχεται αποκλειστικά από εγκεφαλική δραστηριότητα. Το EEG είναι ιδιαίτερα ευαίσθητο σε μη-εγκεφαλικές πηγές, όπως βλεφαρισμούς και κινήσεις οφθαλμών (EOG), μυϊκή δραστηριότητα (EMG), μετακινήσεις ηλεκτροδίων και ηλεκτρικό θόρυβο από το δίκτυο. Σε πειράματα που αφορούν γνωστικό φορτίο, η παρουσία τέτοιων artifacts είναι συχνά εντονότερη, καθώς οι συμμετέχοντες μπορεί να κουράζονται, να σφίγγουν τους μύες του προσώπου ή να αλλάζουν στάση κατά τη διάρκεια της καταγραφής.

Ένα σημαντικό σημείο είναι ότι τα artifacts δεν επηρεάζουν μόνο απλές μετρήσεις, όπως την ισχύ σε συγκεκριμένες ζώνες συχνοτήτων, αλλά μπορούν να αλλοιώσουν και πιο σύνθετες περιγραφές της δυναμικής του σήματος. Για παράδειγμα, μια περιοδική μυϊκή σύσπαση μπορεί να εισαγάγει τεχνητή κανονικότητα ή αυξημένη πολυπλοκότητα, η οποία δεν σχετίζεται με τη γνωστική κατάσταση του συμμετέχοντα. Αυτό σημαίνει ότι μη-γραμμικά χαρακτηριστικά ενδέχεται να «ανιχνεύουν» artifacts αντί για πραγματικές εγκεφαλικές μεταβολές, αν η ποιότητα του σήματος δεν ληφθεί υπόψη.

Πέρα από την ποιότητα του σήματος, δύο εγγενείς ιδιότητες του EEG δυσχεραίνουν τη μοντελοποίηση και την εξαγωγή γενικεύσιμων συμπερασμάτων: η μη-στασιμότητα και η δια-υποκειμενική μεταβλητότητα. Η μη-στασιμότητα αναφέρεται στο γεγονός ότι οι στατιστικές ιδιότητες του EEG μεταβάλλονται στον χρόνο, ακόμη και μέσα στην ίδια πειραματική συνθήκη. Η δια-υποκειμενική μεταβλητότητα σημαίνει ότι διαφορετικά άτομα παρουσιάζουν διαφορετικά βασικά επίπεδα δραστηριότητας και διαφορετικές αποκρίσεις στο ίδιο γνωστικό έργο. Ως αποτέλεσμα, μοτίβα που είναι ισχυρά για έναν συμμετέχοντα μπορεί να μην εμφανίζονται με τον ίδιο τρόπο σε κάποιον άλλο.

Οι παραπάνω παράγοντες καθιστούν τη μεθοδολογική εγκυρότητα της αξιολόγησης ιδιαίτερα κρίσιμη. Με τον όρο αυτό εννοούμε κατά πόσο το πρωτόκολλο αξιολόγησης αντανακλά ρεαλιστικά το πρόβλημα που θέλουμε να λύσουμε και αν τα αποτελέσματα που προκύπτουν μπορούν να γενικευτούν πέρα από τα δεδομένα εκπαίδευσης. Η βιβλιογραφία έχει δείξει ότι πρακτικές cross-validation σε επίπεδο παραθύρων (sample-wise), όπου δεδομένα από τον ίδιο συμμετέχοντα εμφανίζονται τόσο στην εκπαίδευση όσο και στον έλεγχο, μπορούν να οδηγήσουν σε *data leakage* και υπερεκτίμηση της απόδοσης [4]. Σε αυτή την περίπτωση, το μοντέλο μαθαίνει κυρίως subject-specific χαρακτηριστικά και όχι γενικά μοτίβα που σχετίζονται με το γνωστικό φορτίο.

Αντίθετα, η subject-wise αξιολόγηση, και ειδικότερα η στρατηγική Leave-One-Subject-Out (LOSO), αποτελεί πιο αυστηρή και ρεαλιστική προσέγγιση όταν ο στόχος είναι η εφαρμογή του μοντέλου σε νέους χρήστες. Σε αυτό το πλαίσιο, το μοντέλο αξιολογείται αποκλειστικά σε δεδομένα από συμμετέχοντες που δεν έχουν χρησιμοποιηθεί κατά την εκπαίδευση, μειώνοντας τον κίνδυνο υπερεκτίμησης και ενισχύοντας τη μεθοδολογική αξιοπιστία των αποτελεσμάτων [5].

## 2.4 Σύνδεση με τη μεθοδολογία της παρούσας εργασίας

Συνοψίζοντας, το παρόν κεφάλαιο ανέδειξε ότι το EEG αποτελεί ένα σήμα με υψηλή πληροφοριακή αξία, αλλά ταυτόχρονα με σημαντικές ιδιαιτερότητες που επηρεάζουν την ανάλυση και την ερμηνεία του. Η διάκριση μεταξύ καταστάσεων όπως η κατάσταση ηρεμίας και η νοητική αριθμητική δεν περιορίζεται στην απλή ανίχνευση αλλαγών στην ισχύ συγκεκριμένων συχνοτικών ζωνών, αλλά σχετίζεται με τον τρόπο με τον οποίο αναδιοργανώνεται η χρονική δομή και η δυναμική της συλλογικής νευρωνικής δραστηριότητας.

Παράγοντες όπως η μη-στασιμότητα του EEG, η παρουσία artifacts και η έντονη δια-υποκειμενική μεταβλητότητα καθιστούν σαφές ότι απαιτούνται προσεκτικές και βιοϊατρικά τεκμηριωμένες μεθοδολογικές επιλογές. Χωρίς την κατάλληλη διαχείριση αυτών των ζητημάτων, υπάρχει αυξημένος κίνδυνος τα εξαγόμενα χαρακτηριστικά ή οι επιδόσεις των μοντέλων να αντανακλούν ιδιαιτερότητες των δεδομένων και όχι ουσιαστικές διαφορές στη γνωστική κατάσταση.

Με βάση τα παραπάνω, η παρούσα εργασία υιοθετεί μια μεθοδολογία που συνδυάζει προσαρμοστικές φασματικές αναπαραστάσεις με μη-γραμμικούς δείκτες δυναμικής, με έμφαση στη Recurrence Quantification Analysis (RQA), καθώς και αυστηρή subject-wise στρατηγική αξιολόγησης. Οι επιλογές αυτές αποσκοπούν αφενός στη σύλληψη πληροφοριών που δεν είναι εύκολα ανιχνεύσιμες με κλασικές προσεγγίσεις και αφετέρου στη διασφάλιση ότι τα αποτελέσματα μπορούν να γενικευτούν σε νέους συμμετέχοντες.

Το επόμενο κεφάλαιο παρουσιάζει αναλυτικά τη μεθοδολογία που ακολουθήθηκε, περιγράφοντας κάθε στάδιο του υπολογιστικού pipeline και δείχνοντας πώς το βιοϊατρικό υπόβαθρο που αναπτύχθηκε στο παρόν κεφάλαιο μεταφράζεται σε συγκεκριμένες υπολογιστικές και πειραματικές επιλογές.

## ΚΕΦΑΛΑΙΟ 3

### ΣΧΕΤΙΚΕΣ ΕΡΕΥΝΕΣ

---

- 3.1 Task paradigms και φυσιολογική τεκμηρίωση του mental arithmetic
  - 3.2 Φασματικά και χρονοφασματικά χαρακτηριστικά: από PSD σε data-driven ζώνες
  - 3.3 Nonlinear/dynamic χαρακτηριστικά: entropy και recurrence-based αναπαραστάσεις
  - 3.4 Deep learning και end-to-end pipelines για mental workload/mental arithmetic
  - 3.5 Πρωτόκολλα αξιολόγησης, cross-subject γενίκευση και κίνδυνοι leakage
  - 3.6 Σχέση με BCI βιβλιογραφία και μεταφορά μεθοδολογικών συμπερασμάτων
  - 3.7 Σύνθεση κενών και κατεύθυνση προς την παρούσα μεθοδολογία
- 

Η ανάλυση ηλεκτροεγκεφαλογραφικών (EEG) σημάτων για την εκτίμηση του γνωστικού φόρτου (*mental workload*) και ειδικότερα για τη διάκριση καταστάσεων όπως *rest* έναντι *mental arithmetic*, αποτελεί διαχρονικά ένα από τα πλέον μελετημένα προβλήματα στη βιβλιογραφία της υπολογιστικής νευροεπιστήμης και των συστημάτων BCI. Το ενδιαφέρον αυτό δικαιολογείται τόσο από τη θεωρητική σημασία της κατανόησης των νευρωνικών μηχανισμών της γνωστικής επιβάρυνσης, όσο και από πρακτικές εφαρμογές σε HCI, συστήματα υποβοήθησης χειριστών και περιβάλλοντα υψηλού κινδύνου, όπως η αεροπορία. Οι πρώιμες μελέτες εστιάζουν σε φυσιολογικές και νευροφυσιολογικές συσχετίσεις της νοητικής αριθμητικής με EEG και συναφή μέτρα, παρέχοντας ενδείξεις για μεταβολές τόσο στη φασματική ισχύ όσο και στη δυναμική δραστηριότητα υπό αυξημένο γνωστικό φόρτο [8, 9, 10, 11, 12, 13, 14, 15].

Παράλληλα, η πολυτροπική επιβεβαίωση μέσω EEG και fMRI έχει χρησιμοποιηθεί για να ενισχύσει την ανιχνευσιμότητα τέτοιων γνωστικών καταστάσεων, χωρίς ωστόσο να επιλύει πλήρως το ζήτημα της γενίκευσης μεταξύ υποκειμένων [7].

Σε μεθοδολογικό επίπεδο, η σχετική βιβλιογραφία μπορεί να οργανωθεί γύρω από τέσσερις βασικούς άξονες: (i) φασματικά και χρονοφασματικά χαρακτηριστικά σε συνδυασμό με κλασικούς ταξινομητές, (ii) μη γραμμικά και δυναμικά χαρακτηριστικά όπως entropy και recurrence-based μέτρα, (iii) βαθιά μάθηση και *end-to-end* προσεγγίσεις, και (iv) πρωτόκολλα αξιολόγησης και ζητήματα cross-subject γενίκευσης, όπου έχουν αναδειχθεί συστηματικά κίνδυνοι υπερεκτίμησης της απόδοσης λόγω διαρροής πληροφορίας και ακατάλληλου partitioning [5, 4, 3]. Στις επόμενες υποενότητες παρουσιάζονται οι κυρίαρχες τάσεις σε καθέναν από αυτούς τους άξονες, αναδεικνύοντας ταυτόχρονα τα κενά που οδηγούν φυσικά στη μεθοδολογική επιλογή της παρούσας εργασίας.

### 3.1 Task paradigms και φυσιολογική τεκμηρίωση του mental arithmetic

Το mental arithmetic χρησιμοποιείται εκτενώς ως *controlled cognitive workload task*, επιτρέποντας είτε τη δυαδική διάκριση *rest vs. task* είτε τη διαβάθμιση επιπέδων γνωστικού φόρτου. Πλήθος εργασιών εστιάζει στη συσχέτιση μεταβολών του EEG με την απόδοση στο έργο ή με συνοδά φυσιολογικά μέτρα, όπως δείκτες του αυτόνομου νευρικού συστήματος, καταδεικνύοντας ότι η νοητική αριθμητική προκαλεί συνεπείς αλλά έντονα υποκειμενο-εξαρτώμενες μεταβολές [10, 11, 13, 14, 15]. Παράλληλα, μελέτες που εξετάζουν έννοιες όπως η *neural efficiency* ή πληθυσμούς με ιδιαίτερα γνωστικά/κλινικά χαρακτηριστικά υπογραμμίζουν ότι τα EEG patterns του mental arithmetic επηρεάζονται από παράγοντες πέραν της εκάστοτε ταξινομητικής μεθόδου [11, 13]. Η πολυτροπική συμφωνία EEG-fMRI ενισχύει την εγκυρότητα του mental arithmetic ως γνωστικού ερεθίσματος, χωρίς ωστόσο να εγγυάται αυτομάτως αξιόπιστη cross-subject απόδοση [7].

Η παραπάνω φυσιολογική τεκμηρίωση θέτει το υπόβαθρο για τη μελέτη των χαρακτηριστικών που μπορούν να αξιοποιηθούν υπολογιστικά, με την πλειονότητα των προσεγγίσεων να ξεκινά ιστορικά από τη φασματική ανάλυση.

### 3.2 Φασματικά και χρονοφασματικά χαρακτηριστικά: από PSD σε data-driven ζώνες

Η επικρατέστερη πρακτική στη βιβλιογραφία βασίζεται στην εξαγωγή φασματικών χαρακτηριστικών, όπως η ισχύς ανά ζώνη συχνοτήτων και οι σχετικές αναλογίες ισχύος, καθώς και σε χρονοφασματικές αναπαραστάσεις (π.χ. STFT) με παραθυροποίηση και εξαγωγή στατιστικών δεικτών. Η χρήση φορητών EEG συστημάτων και η εφαρμογή σε ρεαλιστικά σενάρια, όπως προσομοιωτές πτήσης, ευνοεί τέτοιες υπολογιστικά αποδοτικές ροές χαρακτηριστικών [16]. Ωστόσο, ένα κρίσιμο μειονέκτημα των προσεγγίσεων αυτών είναι η εξάρτησή τους από προκαθορισμένες (*canonical*) ζώνες συχνοτήτων, οι οποίες δεν είναι κατ' ανάγκη βέλτιστες για κάθε dataset ή πειραματικό πρωτόκολλο.

Ως απάντηση σε αυτό το ζήτημα, έχουν προταθεί *data-driven* μέθοδοι αυτόματης εύρεσης ορίων ζωνών, όπως η χρήση decision trees για την ανακατασκευή του power spectrum και την απομόνωση πληροφοριακών components [17]. Η κατεύθυνση αυτή αναδεικνύει την ανάγκη για *adaptive spectral decomposition*, ιδίως όταν ο στόχος είναι η μείωση της εξάρτησης από αυθαίρετες επιλογές και η ενίσχυση της μεταφερσιμότητας σε cross-subject συνθήκες.

Παρά τη χρησιμότητα των φασματικών χαρακτηριστικών, η εγγενώς μη στάσιμη και δυναμική φύση του EEG έχει οδηγήσει στην αναζήτηση πιο εκφραστικών, μη γραμμικών περιγραφών.

### 3.3 Nonlinear/dynamic χαρακτηριστικά: entropy και recurrence-based αναπαραστάσεις

Ο EEG αποτελεί κατεξοχήν *nonstationary* και δυναμικό σήμα, γεγονός που έχει οδηγήσει στην αυξανόμενη αξιοποίηση μη γραμμικών χαρακτηριστικών. Ενδεικτικά, αρκετές προσεγγίσεις βασίζονται σε entropy-based δείκτες, οι οποίοι τροφοδοτούνται σε ακολουθιακά μοντέλα (RNN/GRU/LSTM) για την ταξινόμηση mental arithmetic [18]. Παράλληλα, οι recurrence plots έχουν χρησιμοποιηθεί ως δομικές αναπαραστάσεις χρονοσειρών, επιτρέποντας την κωδικοποίηση της επαναληπτικότητας και της γεωμετρίας των τροχιών στο phase space, με επιτυχία σε συγγενή EEG tasks όπως η ανίχνευση επιληπτικών κρίσεων [19].

Συναφώς, έχουν προταθεί συνδυαστικές ροές που ενσωματώνουν χρονοφασματική ανάλυση (STFT) και embedding για την εφαρμογή Recurrence Quantification Analysis (RQA) σε EEG χρονοσειρές, με έμφαση στις σχεδιαστικές επιλογές του embedding και της παραθυροποίησης [1]. Η αυξανόμενη υιοθέτηση τέτοιων δυναμικών δεικτών υποδεικνύει ότι οι μη γραμμικές προσεγγίσεις μπορούν να λειτουργήσουν συμπληρωματικά προς τη φασματική πληροφορία, συλλαμβάνοντας μεταβάσεις και δομικές αλλαγές που δεν αποτυπώνονται ως απλή μετατόπιση ισχύος [2].

Οι παραπάνω παρατηρήσεις έχουν ενσωματωθεί τόσο σε κλασικά όσο και σε σύγχρονα deep learning pipelines, τα οποία παρουσιάζονται στη συνέχεια.

### **3.4 Deep learning και *end-to-end* pipelines για mental workload-/mental arithmetic**

Η διάδοση των deep learning αρχιτεκτονικών έχει οδηγήσει σε πληθώρα *end-to-end* ή ημι-*end-to-end* προσεγγίσεων για mental workload, συχνά βασισμένων σε CNN/RNN υβρίδια ή multitask σχήματα [19, 20]. Παράλληλα, αναπτύσσονται μέθοδοι *explainable machine learning* με στόχο την ερμηνευσιμότητα των αποφάσεων σε κρίσιμες εφαρμογές [21], καθώς και νέες αρχιτεκτονικές ή τεχνικές pooling που επιδιώκουν τη βελτιστοποίηση της απόδοσης [22]. Επιπλέον, έχει δοθεί έμφαση στη μείωση διαστατικότητας και στην επιλογή χαρακτηριστικών, ιδίως σε σενάρια πραγματικού χρόνου [23].

Ωστόσο, ένα επαναλαμβανόμενο μοτίβο στη βιβλιογραφία είναι ότι η υψηλή απόδοση των deep μοντέλων εξαρτάται έντονα από το πρωτόκολλο αξιολόγησης. Η χρήση subject-dependent splits και η ανεπαρκής αποφυγή leakage οδηγούν συχνά σε μη ρεαλιστικές εκτιμήσεις απόδοσης, γεγονός που καθιστά αναγκαία μια πιο προσεκτική συζήτηση γύρω από την αξιολόγηση.

### **3.5 Πρωτόκολλα αξιολόγησης, cross-subject γενίκευση και κίνδυνοι leakage**

Η αξιολόγηση στην EEG ταξινόμηση αποτελεί κρίσιμο παράγοντα εγκυρότητας και όχι απλώς τεχνική λεπτομέρεια. Πρόσφατες μελέτες έχουν δείξει ότι ακατάλληλες

στρατηγικές partitioning μπορούν να οδηγήσουν σε σοβαρή υπερεκτίμηση της απόδοσης, ιδιαίτερα σε deep learning pipelines [5, 4]. Παράλληλα, έχει αναδειχθεί ότι η cross-subject γενίκευση επηρεάζεται από distribution shifts μεταξύ υποκειμένων, τα οποία απαιτούν ρητή αντιμετώπιση [3].

Ειδικά στο mental workload, εφαρμογές σε ρεαλιστικά περιβάλλοντα, όπως πιλότοι με ασύρματα EEG headsets, καταδεικνύουν ότι η subject-wise αξιολόγηση αποτελεί το μόνο ρεαλιστικό deployment scenario [16]. Κατά συνέπεια, η επιλογή πρωτοκόλλων τύπου LOSO δεν αποτελεί απλώς αυστηρότερη αξιολόγηση, αλλά προϋπόθεση εξωτερικής εγκυρότητας.

### **3.6 Σχέση με BCI βιβλιογραφία και μεταφορά μεθοδολογικών συμπερασμάτων**

Παρότι η παρούσα εργασία εστιάζει στο mental arithmetic, σημαντικά μεθοδολογικά συμπεράσματα προκύπτουν και από συγγενείς περιοχές της BCI βιβλιογραφίας, όπως motor imagery και emotion recognition. Σε αυτές τις περιοχές έχουν διερευνηθεί εκτενώς pipelines χαρακτηριστικών, στρατηγικές preprocessing και πρωτόκολλα αξιολόγησης [24, 25, 26, 27]. Τα ευρήματα αυτά ενισχύουν την άποψη ότι η επιλογή χαρακτηριστικών επηρεάζει καθοριστικά τη μεταφερσιμότητα και ότι η απόδοση χωρίς σαφές subject-wise πλαίσιο έχει περιορισμένη πρακτική αξία. Επιπλέον, μελέτες για EEG biomarkers υπογραμμίζουν τη σημασία της εστίασης σε σταθερά και βιολογικά ερμηνεύσιμα χαρακτηριστικά, αντί για artefacts συγκεκριμένων datasets [28].

### **3.7 Σύνθεση κενών και κατεύθυνση προς την παρούσα μεθοδολογία**

Συνοψίζοντας, η βιβλιογραφία καταδεικνύει ότι τα φασματικά χαρακτηριστικά είναι ισχυρά αλλά ευαίσθητα σε επιλογές ζωνών και nonstationarity [16, 17], ότι οι nonlinear/dynamic προσεγγίσεις αποτελούν ανερχόμενο άξονα για την αποτύπωση δομικών αλλαγών [18], και ότι οι deep learning μέθοδοι απαιτούν αυστηρά πρωτόκολλα αξιολόγησης για την αποφυγή leakage [5, 4].

Με βάση τα παραπάνω, η παρούσα εργασία τοποθετείται στο σημείο τομής των παραπάνω αξόνων: υιοθετεί *adaptive spectral decomposition* για τη μείωση της εξάρτησης από προκαθορισμένες ζώνες [17], ενσωματώνει *nonlinear/dynamic* χαρακτηριστικά μέσω RQA ώστε να κωδικοποιήσει τη χρονική δομή και τις μεταβάσεις [1, 2], και αξιολογεί αυστηρά με subject-wise πρωτόκολλο (LOSO), σε ευθυγράμμιση με τα σύγχρονα ευρήματα για cross-subject αξιοπιστία [5, 4].

## ΚΕΦΑΛΑΙΟ 4

# ΑΠΟ ΤΗ ΒΙΒΛΙΟΓΡΑΦΙΑ ΣΤΟ PIPELINE: ΑΝΑΠΑΡΑΣΤΑΣΗ, ΜΗ-ΓΡΑΜΜΙΚΑ ΧΑΡΑΚΤΗΡΙΣΤΙΚΑ ΚΑΙ ΈΓΚΥΡΗ ΑΞΙΟΛΟΓΗΣΗ

- 
- 4.1 Αναπαράσταση πριν από RQA: γιατί ο “χώρος καταστάσεων” είναι το πραγματικό σημείο-κλειδί
  - 4.2 Μη-γραμμικά χαρακτηριστικά και LOSO: όταν η δυναμική πληροφορία πρέπει να επιβιώσει σε νέο υποκείμενο
  - 4.3 Η αξιολόγηση ως επιστημονική δέσμευση: leakage, subject-wise split και nested επιλογές
  - 4.4 Cross-subject γενίκευση ως distribution shift: γιατί η σταθερότητα χαρακτηριστικών είναι στόχος σχεδιασμού
  - 4.5 Κλασικό baseline mental arithmetic: τι κερδίζουμε και τι χάνουμε με fixed-band/γραμμικές προσεγγίσεις
  - 4.6 Συνθετική αποτίμηση: γιατί η βιβλιογραφία συγκλίνει σε Αναπαράσταση + RQA + LOSO
- 

Στο παρόν κεφάλαιο παρουσιάζονται και αναλύονται επιλεγμένες εργασίες που διαμόρφωσαν άμεσα τον τρόπο με τον οποίο σχεδιάστηκε το pipeline της παρούσας διπλωματικής. Η επιλογή δεν βασίζεται μόνο στη θεματική συνάφεια (mental

workload/mental arithmetic), αλλά κυρίως στη μεθοδολογική τους αξία: (i) πώς ορίζεται η δυναμική πληροφορία στο EEG μέσω μη-γραμμικών περιγραφών (ιδίως recurrence/RQA), (ii) γιατί η αναπαράσταση του σήματος πριν από την εξαγωγή χαρακτηριστικών επηρεάζει καθοριστικά το τι «βλέπει» τελικά η μέθοδος, και (iii) γιατί το evaluation (split, leakage, subject-wise πρωτόκολλα) είναι θεμέλιο εξωτερικής εγκυρότητας.

Κεντρική υπόθεση της παρούσας εργασίας είναι ότι (α) οι δυναμικές περιγραφές όπως τα RQA measures και (β) οι προσαρμοστικές φασματικές αναπαραστάσεις μπορούν να παράγουν χαρακτηριστικά πιο ανθεκτικά στο cross-subject variability, υπό την προϋπόθεση ότι η αξιολόγηση προσομοιώνει ρεαλιστική χρήση σε νέο υποκείμενο (LOSO). Στις επόμενες ενότητες αναδεικνύεται καθαρά τι υιοθετεί η παρούσα εργασία, τι επεκτείνει και σε ποια σημεία διαφοροποιείται.

Ο στόχος εδώ δεν είναι να παρατεθεί μια «λίστα papers», αλλά να χτιστεί μια αλυσίδα λογικής: από το πώς αναπαριστάται το EEG, στο πώς μετρίεται η δυναμική του, και τελικά στο πώς αξιολογείται η γενίκευση. Με αυτόν τον τρόπο, η βιβλιογραφία λειτουργεί ως αιτιολόγηση του design: γιατί επιλέγονται RQA χαρακτηριστικά, γιατί προηγείται φασματική αναπαράσταση (κλασική ή προσαρμοστική), και γιατί η subject-wise αξιολόγηση είναι προϋπόθεση και όχι «επιλογή ευκολίας».

#### **4.1 Αναπαράσταση πριν από RQA: γιατί ο “χώρος καταστάσεων” είναι το πραγματικό σημείο-κλειδί**

Η εργασία των Furman *et al.* [1] είναι καθοριστική επειδή μετακινεί την προσοχή από το «ποιο RQA μέτρο» ή «ποιος ταξινομητής» στο πιο θεμελιώδες ερώτημα: σε ποιον χώρο ορίζεται η έννοια του recurrence. Η RQA εξαρτάται άμεσα από το πότε δύο καταστάσεις θεωρούνται «κοντά», άρα το recurrence plot δεν είναι ανεξάρτητο αντικείμενο: είναι προϊόν της αναπαράστασης που επιλέγουμε.

Σε αντίθεση με συστήματα όπου η δυναμική είναι σχετικά «καθαρή» και οι υποθέσεις της θεωρίας embedding προσεγγίζονται ικανοποιητικά, το EEG είναι μη-στασίμο, πολυκαναλικό, με artifacts, και επηρεάζεται από volume conduction και δια-υποκειμενική μεταβλητότητα. Επομένως, το τι σημαίνει «κοντινή κατάσταση» δεν είναι ουδέτερο: μπορεί να αντιστοιχεί σε μοιραζόμενη φυσιολογική δομή ή σε

τεχνητή ομοιότητα λόγω θορύβου/παραμετροποίησης.

Η κλασική RQA σε χρονοσειρές προϋποθέτει *phase-space reconstruction* μέσω *time-delay embedding*, εισάγοντας υπερπαραμέτρους όπως  $m$ ,  $\tau$  και  $\varepsilon$  [1]. Στο EEG, η επιλογή αυτών των παραμέτρων είναι δύσκολη όχι μόνο επειδή συχνά γίνεται ευρετικά, αλλά και επειδή τα κλασικά κριτήρια (mutual information για  $\tau$ , FNN για  $m$ ) δεν είναι απαραίτητα σταθερά σε όλες τις χρονικές κλίμακες, σε όλα τα κανάλια ή σε όλους τους συμμετέχοντες. Έτσι, ένα embedding που λειτουργεί ικανοποιητικά σε μία περίπτωση μπορεί να είναι ασθενές σε άλλη, ενισχύοντας το *cross-subject shift*.

Αν η διαδικασία embedding γίνει πλήρως «ορθόδοξα», προκύπτει ένα πρακτικό δίλημμα: είτε (α) επιλέγονται  $m, \tau$  ανά υποκείμενο/κανάλι/segment (άρα αυξάνεται δραματικά ο βαθμός ελευθερίας και ο κίνδυνος έμμεσης υπερπροσαρμογής), είτε (β) κλειδώνουν κοινές τιμές (άρα η μέθοδος χάνει προσαρμοστικότητα και μπορεί να μην είναι βέλτιστη για σημαντικό μέρος των δεδομένων). Η Furman *et al.* χρησιμοποιούν τη δεύτερη επιλογή ως ρεαλιστικό συμβιβασμό [1], και αυτό από μόνο του είναι χρήσιμο συμπέρασμα για pipelines που στοχεύουν σε LOSO.

Οι Furman *et al.* προτείνουν να μεταφερθεί η έννοια «κατάσταση του συστήματος» από το χρονικό πεδίο στο φασματικό: αντί για embedded τροχιές, κάθε state ορίζεται ως ένα τοπικό φασματικό στιγμιότυπο (power-spectrum vector) από STFT παράθυρο [1]. Αυτό ευθυγραμμίζεται με μια βασική νευροφυσιολογική διαπίστωση: πολλές γνωστικές μεταβολές αντανακλώνται ως μεταβολές σε ρυθμούς/ζώνες. Έτσι, η recurrence ανάλυση δεν μετρά απλώς «πόσο μοιάζουν κυματομορφές», αλλά «πόσο και πώς επανεμφανίζονται φασματικά προφίλ».

Η STFT επιβάλλει μια υπόθεση τοπικής στασιμότητας εντός παραθύρου: αντί να ζητάμε από μια χρονοσειρά να είναι σταθερή σε όλη τη διάρκεια, ζητάμε να είναι αρκετά σταθερή σε μικρά τμήματα. Αυτό είναι πιο ρεαλιστικό για EEG και λειτουργεί ως «μετασχηματισμός» που εξομαλύνει μέρος του sample-level θορύβου σε στατιστικά φασματικά μεγέθη. Έτσι, η έννοια της εγγύτητας μεταφέρεται σε έναν χώρο όπου η νευροφυσιολογική ερμηνεία (ρυθμοί/zones) είναι πιο άμεση.

Στην κλασική TD-EMB-RQA, οι καταστάσεις κατασκευάζονται απευθείας από τη χρονοσειρά:

$$x_i = (u_i, u_{i+\tau}, \dots, u_{i+(m-1)\tau}), \quad R_{i,j} = \Theta(\varepsilon - \|x_i - x_j\|).$$

Στο STFT-RQA, κάθε state είναι ένα διάλυμα φασματικής ισχύος (π.χ. 257 τιμές

στο 0–50 Hz) από ένα STFT παράθυρο [1]. Η Ευκλείδεια απόσταση παραμένει ο «γεωμετρικός» πυρήνας της recurrence έννοιας, αλλά η ερμηνεία αλλάζει: στο TD-EMB-RQA η απόσταση σχετίζεται με το σχήμα/μορφή της κυματομορφής σε καθυστέρηση, ενώ στο STFT-RQA μετρά ομοιότητα φασματικών προφίλ.

Με TD-EMB-RQA, δύο χρονικές στιγμές θεωρούνται παρόμοιες αν οι καθυστε-  
ρημένες τιμές τους σχηματίζουν παρόμοιο «μοτίβο» στο embedding. Με STFT-RQA, δύο χρονικές στιγμές θεωρούνται παρόμοιες αν έχουν παρόμοιο φάσμα ισχύος. Αυτό μεταφέρει την έννοια της recurrence από την μορφολογία της κυματομορφής στην οργάνωση ρυθμικών/φασματικών καταστάσεων, κάτι που ταιριάζει συχνά καλύτερα σε γνωστικές εφαρμογές.

(1) Το  $\epsilon$  επιλέγεται ως 40 εκατοστημόριο της κατανομής αποστάσεων. Στόχος είναι να σταθεροποιηθεί η πυκνότητα recurrences, όμως η διαστατικότητα παίζει ρόλο: στον 257-διάστατο χώρο (STFT) οι αποστάσεις τείνουν να συγκεντρώνονται (*distance concentration*) πιο έντονα από ό,τι σε χαμηλότερες διαστάσεις (embedding). Άρα, ίδιο percentile δεν σημαίνει ίδια «γεωμετρική αυστηρότητα». (2) Η σταθεροποίηση  $m = 5$  και  $\tau = 9$  [1] δείχνει το πρακτικό κόστος πλήρους εξατομίκευσης. Σε LOSO πλαίσιο, per-subject tuning είναι όχι μόνο δύσκολο, αλλά και μεθοδολογικά επισφαλές, γιατί μπορεί να εισαγάγει έμμεσο leakage και να θολώσει τη συγκρισιμότητα.

Η παρούσα εργασία δεν χρησιμοποιεί τα παραπάνω ως «επιχείρημα κατά» της μεθόδου, αλλά ως υπενθύμιση ότι η σύγκριση (TD-EMB-RQA vs STFT-RQA) δεν είναι μόνο αλλαγή αναπαραστάσης: είναι και αλλαγή γεωμετρίας χώρου. Για αυτό, η παρούσα διπλωματική δίνει ιδιαίτερη έμφαση στο evaluation (LOSO) και στη σταθερότητα των χαρακτηριστικών σε cross-subject setting, ώστε οποιαδήποτε βελτίωση να μην είναι artifact ενός ευνοϊκού splitting.

Η βασική «διδασκαλία» εδώ είναι ότι η RQA δεν είναι μονολιθική: λειτουργεί όσο καλά επιτρέπει ο χώρος καταστάσεων. Η παρούσα εργασία υιοθετεί την αρχή *representation-first* και μεταφέρει τη λογική από το eyes open/closed σε mental arithmetic, όπου οι μεταβολές είναι συχνά πιο λεπτές και μεταβατικές. Με άλλα λόγια, δεν αντιμετωπίζεται η RQA ως «μαγικό χαρακτηριστικό», αλλά ως εργαλείο που χρειάζεται σωστή είσοδο.

## 4.2 Μη-γραμμικά χαρακτηριστικά και LOSO: όταν η δυναμική πληροφορία πρέπει να επιβιώσει σε νέο υποκείμενο

Η εργασία των Zheng & Weng [2] είναι ενδεικτική μιας γραμμής προσέγγισης στο mental workload όπου το power (ή τα απλά band features) δεν θεωρούνται επαρκή από μόνα τους. Η βασική ιδέα είναι ότι το workload δεν αλλάζει μόνο «πόση ενέργεια» υπάρχει σε μία ζώνη, αλλά μπορεί να επηρεάσει την κανονικότητα, την πολυπλοκότητα και τη χρονική οργάνωση του EEG.

Στην πράξη, το workload συχνά συνοδεύεται από μεταβολές που δεν περιγράφονται πλήρως από μέσους όρους ισχύος: αλλαγές στη διακοπτόμενη/παροδική εμφάνιση ρυθμών, μεταβολές στη «σταθερότητα» του σήματος, ή αλλαγές στη δομή χρονικών εξαρτήσεων. Δείκτες όπως entropy, fractal dimensions και complexity επιχειρούν να αποτυπώσουν ακριβώς αυτή τη διάσταση: όχι «πόσο μεγάλο είναι το σήμα», αλλά «πώς είναι οργανωμένο».

Οι συγγραφείς χρησιμοποιούν ένα σύνολο 10 nonlinear δεικτών (entropy measures, fractal dimensions, DFA/Hurst, LZ complexity, Lyapunov), δηλαδή μια «πολυόψη» περιγραφή της δυναμικής. Η αξία αυτής της στρατηγικής είναι ότι δεν ποντάρει σε μία μοναδική υπόθεση, αλλά καλύπτει διαφορετικές όψεις του dynamical regime.

Ένα μεγάλο πλεονέκτημα μιας τέτοιας συλλογής είναι η κάλυψη πολλών δυναμικών υποθέσεων. Παράλληλα, όμως, αυξάνει ο κίνδυνος (α) πλεονασμού/συσχέτισης μεταξύ χαρακτηριστικών και (β) δυσκολίας ερμηνείας: αν το μοντέλο αποδίδει, δεν είναι πάντα σαφές ποια δυναμική ιδιότητα είναι ο κύριος φορέας πληροφορίας. Αυτό δεν ακυρώνει την προσέγγιση, αλλά είναι χρήσιμο για να τοποθετηθεί η παρούσα εργασία που επιλέγει πιο συνεκτικό πλαίσιο (RQA) αντί για πολύ ετερογενή οικογένεια.

Το πιο σημαντικό όμως στοιχείο για την παρούσα διπλωματική δεν είναι η λίστα των δεικτών, αλλά το ότι η αξιολόγηση γίνεται με LOSO [2]. Αυτό μετατρέπει τη συζήτηση από «υψηλή ακρίβεια» σε «γενίκευση σε νέο άτομο» και υποστηρίζει τη θέση ότι η δυναμική πληροφορία έχει νόημα μόνο όταν δεν καταρρέει σε cross-subject setting.

Σε LOSO, το μοντέλο δεν μπορεί να «αναγνωρίσει» τον συμμετέχοντα μέσω baseline χαρακτηριστικών και να μετατρέψει έμμεσα το task σε identification prob-

lem. Άρα, όταν βλέπουμε υψηλή απόδοση, αυτό είναι ισχυρότερο τεκμήριο ότι το pipeline εντοπίζει δομές που σχετίζονται με την κατάσταση και όχι με το άτομο.

Η παρούσα διπλωματική συγκλίνει στη λογική *nonlinear + LOSO*, αλλά αντί για ευρύ feature zoo επιλέγει ένα πιο συνεκτικό δυναμικό πλαίσιο (RQA), ώστε τα χαρακτηριστικά να συνδέονται με δομές στο recurrence plot (π.χ. determinism, laminarity) και να είναι πιο ερμηνεύσιμα. Επίσης, σε αντίθεση με pipelines που θεωρούν δεδομένη τη φασματική αναπαράσταση, εδώ εξετάζεται ρητά ο ρόλος της (κλασικής ή προσαρμοστικής) decomposition ως «σταθεροποιητή» πριν τη nonlinear εξαγωγή.

### 4.3 Η αξιολόγηση ως επιστημονική δέσμευση: leakage, subject-wise split και nested επιλογές

Οι Brookshire *et al.* [4] και Del Pup *et al.* [5] τεκμηριώνουν ότι στην EEG ταξινόμηση η «απόδοση» μπορεί να είναι περισσότερο συνάρτηση του split παρά του ίδιου του μοντέλου. Δύο λόγοι κάνουν το πρόβλημα ιδιαίτερα έντονο: (i) ισχυρές ενδο-υποκειμενικές συσχετίσεις (segments από το ίδιο άτομο μοιάζουν μεταξύ τους) και (ii) τεχνητή αύξηση δειγμάτων μέσω segmentation, όπου πολλά παράθυρα δεν είναι ανεξάρτητα.

Στην EEG, είναι συνηθισμένο ένα recording να χωρίζεται σε επικαλυπτόμενα windows, παράγοντας μεγάλο αριθμό δειγμάτων. Όμως, δύο κοντινά (ή επικαλυπτόμενα) windows μοιράζονται μεγάλο μέρος της δομής τους: ίδιο baseline, ίδια artifacts, ίδια κατάσταση ηλεκτροδίων. Αν αυτά τα παράθυρα «αναμιχθούν» μεταξύ train και test, τότε το μοντέλο αξιολογείται σε δεδομένα που είναι εξαρτώμενα από το train set.

Η Brookshire *et al.* τονίζουν ότι leakage δεν απαιτεί «ίδια δείγματα» σε train/test. Αρκεί να υπάρχουν εξαρτώμενα τμήματα (π.χ. επικαλυπτόμενα ή πολύ κοντινά χρονικά windows) που μοιράζονται κοινή δομή [4]. Σε αυτή την περίπτωση, ένα ισχυρό μοντέλο μπορεί να μάθει subject fingerprints αντί για την υπογραφή της γνωστικής κατάστασης.

Μπορεί να είναι ένα σταθερό πρότυπο ισχύος, μια ιδιαιτερότητα από impedance ή μια συστηματική μυϊκή δραστηριότητα. Το κρίσιμο είναι ότι αυτά τα μοτίβα (αν εμφανίζονται και στο test λόγω λάθος split) επιτρέπουν σε μοντέλα υψηλής χωρητι-

κόττητας να «κλέψουν» την πρόβλεψη χωρίς να μάθουν γενικούς δείκτες workload.

Οι Del Pup *et al.* δείχνουν ότι bias μπορεί να εμφανιστεί ακόμη και με subject-level split, αν η επιλογή μοντέλου/υπερπαραμέτρων «βλέπει» έμμεσα τα test subjects (π.χ. μέσω μη nested διαδικασίας) [5]. Γι' αυτό προτείνεται nested subject-wise λογική ως πιο αξιόπιστη όταν γίνεται εκτενές model selection.

Αν γίνεται επιλογή υπερπαραμέτρων/μοντέλου με τρόπο που χρησιμοποιεί πληροφορία από το test fold (έστω έμμεσα), τότε το τελικό αποτέλεσμα δεν είναι «καθαρή» εκτίμηση γενίκευσης. Σε πολλές εργασίες αυτό συμβαίνει άθελά τους (π.χ. tuning σε όλα τα data πριν το split). Η συμβολή των Del Pup *et al.* είναι ότι αναδεικνύουν πως ακόμη και σχετικά μικρές παραβιάσεις μπορούν να οδηγήσουν σε συστηματική υπερεκτίμηση [5].

Το LOSO δεν αντιμετωπίζεται ως «μια ακόμη επιλογή CV», αλλά ως ελάχιστη συνθήκη εγκυρότητας. Επιπλέον, η αξιολόγηση καθοδηγεί τον σχεδιασμό: επιλέγονται αναπαραστάσεις/χαρακτηριστικά που είναι λιγότερο πιθανό να κωδικοποιούν subject-specific σταθερές. Αυτός είναι και ο λόγος που στο pipeline δίνεται έμφαση σε (α) δυναμικές δομές (RQA) και (β) αναπαραστάση που επιδιώκει να είναι πιο σταθερή μεταξύ υποκειμένων (π.χ. προσαρμοστικές ζώνες).

#### **4.4 Cross-subject γενίκευση ως distribution shift: γιατί η σταθερότητα χαρακτηριστικών είναι στόχος σχεδιασμού**

Η εργασία [3] δίνει ένα χρήσιμο εννοιολογικό πλαίσιο: η cross-subject αποτυχία δεν είναι απλώς «πιο δύσκολη», αλλά συχνά αντανακλά *distribution shift*. Δηλαδή, οι κατανομές των features αλλάζουν μεταξύ ατόμων και, σε ορισμένες περιπτώσεις, μπορεί να αλλάξει και η σχέση feature-label.

Διαφορές σε κρανιακή/δερματική αγωγιμότητα, τοποθέτηση ηλεκτροδίων, baseline ρυθμούς (π.χ. alpha peak), επίπεδο θορύβου και στρατηγική εκτέλεσης του task οδηγούν σε μετατόπιση των κατανομών. Άρα, ακόμη και με σωστό split (LOSO), το μοντέλο μπορεί να αποτυγχάνει όχι επειδή «δεν είναι αρκετά ισχυρό», αλλά επειδή τα features δεν είναι σταθερά.

Η κανονικοποίηση μπορεί να μειώσει shifts και να βοηθήσει [3], αλλά δεν δημιουργεί νέα πληροφορία: αν ένα χαρακτηριστικό είναι εκ φύσεως subject-specific

(π.χ. απόλυτο band power), η normalization το βελτιώνει μέχρι ενός σημείου, χωρίς να το «μετατρέψει» σε cross-subject σταθερό. Έτσι, το κεντρικό ζητούμενο γίνεται η επιλογή χαρακτηριστικών που αποτυπώνουν πιο δομικές, συνεπείς ιδιότητες.

Η «σταθερότητα» εδώ δεν σημαίνει ότι όλοι οι συμμετέχοντες έχουν ίδιες τιμές χαρακτηριστικών. Σημαίνει ότι η μετάβαση από rest σε task προκαλεί συνεπές *pattern* αλλαγής που μπορεί να μάθει ένα μοντέλο. Αυτό είναι ουσιαστικό για deployment: ένα χαρακτηριστικό μπορεί να έχει διαφορετικό baseline ανά άτομο, αλλά να παρουσιάζει παρόμοια μεταβολή υπό workload.

Η παρούσα εργασία χρησιμοποιεί το πλαίσιο shift ως αιτιολόγηση για: (i) subject-wise αξιολόγηση (LOSO), (ii) προσαρμοστικές/δεδομενοκεντρικές φασματικές αναπαραστάσεις (αντί fixed bands), και (iii) RQA ως περιγραφή δομής (recurring patterns) και όχι μόνο απόλυτων τιμών. Με άλλα λόγια, το shift πλαίσιο δίνει τη «γλώσσα» για να εξηγηθεί γιατί δεν αρκεί να αυξήσουμε την πολυπλοκότητα του classifier: χρειάζεται να σχεδιαστεί καλύτερα η αναπαράσταση και τα features.

#### 4.5 Κλασικό baseline mental arithmetic: τι κερδίζουμε και τι χάνουμε με fixed-band/γραμμικές προσεγγίσεις

Η εργασία [6] είναι χρήσιμη ως σημείο αναφοράς, επειδή επιχειρεί διάκριση επιπέδων δυσκολίας σε mental arithmetic (easy/medium/hard), δηλαδή ένα πιο ρεαλιστικό workload σενάριο από το απλό rest vs task. Παράλληλα, συγκρίνει κλασικές γραμμικές προσεγγίσεις (CSP/band-power), οι οποίες παραμένουν ισχυρά και πρακτικά baselines στην EEG βιβλιογραφία.

Τα γραμμικά features έχουν δύο πλεονεκτήματα: (α) είναι υπολογιστικά απλά και σταθερά, και (β) έχουν πιο καθαρή ερμηνεία (π.χ. «αυξάνεται η ισχύς σε αυτή τη ζώνη»). Επομένως, ακόμη κι αν μια μη-γραμμική προσέγγιση υπερισχύει, έχει αξία να ξέρουμε τι θα πετύχουμε με ένα καλά στημένο baseline.

Τα αποτελέσματα που συνήθως παρατηρούνται σε τέτοιες ρυθμίσεις (καλύτερη διάκριση στα άκρα, δυσκολία στο 3-class) [6] είναι συμβατά με την ιδέα ότι το workload είναι δυναμικά εξελισσόμενο φαινόμενο με μεταβατικές περιόδους και ενδογενή ασάφεια στη «μεσαία» κατάσταση.

Όταν η διάκριση βελτιώνεται με μεγαλύτερα παράθυρα (ή χειροτερεύει σε πολύ

μικρά), αυτό υποδηλώνει ότι η πληροφορία «συσσωρεύεται» στο χρόνο: η κατάσταση δεν είναι στιγμιαία, αλλά έχει διάρκεια/επιμονή και περιόδους μετάβασης. Αυτή η παρατήρηση ταιριάζει φυσικά με δυναμικές προσεγγίσεις όπως η RQA, οι οποίες μετρούν δομές (π.χ. επιμονή, επαναληψιμότητα) και όχι μόνο στιγμιαία ισχύ.

Ο περιορισμός της κλασικής γραμμής για την παρούσα διπλωματική συνοφίζεται σε δύο σημεία: (i) fixed bands μπορούν να είναι suboptimal επειδή οι ρυθμοί (π.χ. alpha peak) μετατοπίζονται μεταξύ ατόμων, και (ii) intra-subject CV δεν τεκμηριώνει deployment σε νέο υποκείμενο. Έτσι, η εργασία λειτουργεί ως χρήσιμο baseline για ενδο-υποκειμενική απόδοση, αλλά όχι ως απόδειξη cross-subject robustness.

Αν οι informative περιοχές συχνότητων μετακινούνται μεταξύ ατόμων, τότε η σταθερή δέσμευση σε fixed bands μπορεί να «κρύβει» πληροφορία για ορισμένους συμμετέχοντες και να την υπερτονίζει για άλλους. Η προσαρμοστική αποσύνθεση εισάγεται ακριβώς για να αντιμετωπιστεί αυτή η πηγή shift.

#### 4.6 Συνθετική αποτίμηση: γιατί η βιβλιογραφία συγκλίνει σε Αναπαράσταση + RQA + LOSO

Οι παραπάνω εργασίες δεν συγκροτούν απλώς «related work», αλλά μια αλληλουχία μεθοδολογικής λογικής που οδηγεί στις επιλογές της παρούσας διπλωματικής.

**(1) Αναπαράσταση.** Η [1] δείχνει ότι η recurrence ανάλυση εξαρτάται από τον χώρο καταστάσεων: αν ο χώρος δεν είναι σταθερός/νοηματικός, η RQA γίνεται παραμετρικά εύθραυστη και ευάλωτη σε cross-subject μεταβολές. Αυτό οδηγεί στη θέση *representation-first*: πρώτα φτιάχνουμε χώρο καταστάσεων με νόημα και μετά εφαρμόζουμε nonlinear ανάλυση.

**(2) Δυναμική πληροφορία.** Η [2] υποστηρίζει ότι nonlinear descriptors μπορούν να αποδώσουν χρήσιμη πληροφορία για workload και, κρίσιμα, ότι αυτή η πληροφορία πρέπει να αξιολογείται σε LOSO συνθήκες για να έχει νόημα. Άρα, το κριτήριο επιτυχίας δεν είναι «πόσο καλά ταξινομεί σε γνωστά άτομα», αλλά «αντέχει η πληροφορία σε νέο άτομο».

**(3) Εγκυρότητα αξιολόγησης.** Οι [5, 4] καθιστούν σαφές ότι χωρίς subject-wise split και πειθαρχία anti-leakage, τα αποτελέσματα μπορεί να είναι συστηματικά αισιόδοξα. Άρα, το evaluation δεν έρχεται «στο τέλος», αλλά καθοδηγεί τον σχεδιασμό.

Στο πλαίσιο της διπλωματικής, αυτό σημαίνει ότι όλες οι αποφάσεις (segmentation, normalization, feature extraction) πρέπει να ορίζονται με τρόπο που δεν «μπερδεύει» train/test σε επίπεδο υποκειμένου.

**(4) Distribution shift.** Η [3] ερμηνεύει τη δυσκολία ως shift πρόβλημα, άρα ο στόχος είναι σταθερότερα χαρακτηριστικά και όχι απλώς μεγιστοποίηση ενδο-υποκειμενικής απόδοσης. Αυτό δικαιολογεί δύο κεντρικές επιλογές της διπλωματικής: προσαρμοστική φασματική αναπαράσταση (για να μειωθεί η εξάρτηση από fixed bands) και RQA (για να μετρηθεί δομή/οργάνωση, όχι μόνο απόλυτες τιμές).

**(5) Baseline αναφορά.** Η [6] δείχνει τι μπορεί να πετύχει η κλασική fixed-band/γραμμική γραμμή σε mental arithmetic, αλλά ταυτόχρονα υπογραμμίζει τους περιορισμούς της όταν ζητείται γενίκευση. Με αυτόν τον τρόπο, λειτουργεί ως σημείο αναφοράς: η διπλωματική δεν «αντικαθιστά» αυθαίρετα τα κλασικά, αλλά δείχνει γιατί χρειάζεται κάτι επιπλέον όταν ο στόχος είναι LOSO.

Με βάση τα παραπάνω, η παρούσα διπλωματική τοποθετείται ως συνεκτική σύνθεση και όχι ως άθροισμα τεχνικών: (i) προσαρμοστική/δεδομενοκεντρική φασματική αναπαράσταση ώστε ο χώρος καταστάσεων να είναι πιο σταθερός, (ii) RQA ως δομημένο πλαίσιο εξαγωγής δυναμικής πληροφορίας, και (iii) LOSO αξιολόγηση ως ελάχιστη συνθήκη εγκυρότητας που ευθυγραμμίζει τα συμπεράσματα με ρεαλιστικό deployment.

Έχοντας θεμελιώσει γιατί (α) η αναπαράσταση προηγείται της nonlinear ανάλυσης, (β) οι δυναμικές περιγραφές πρέπει να επιβιώνουν σε LOSO, και (γ) το evaluation καθορίζει την εγκυρότητα, το επόμενο βήμα είναι η συγκεκριμενοποίηση: πώς μεταφράζονται όλα αυτά σε ένα πρακτικό, αναπαραγωγίμο pipeline πάνω στο EEGMAT. Το επόμενο κεφάλαιο περιγράφει αναλυτικά την προεπεξεργασία, την οργάνωση των δεδομένων, την αποσύνθεση συχνοτήτων και τον ακριβή τρόπο εξαγωγής/σύντηξης των χαρακτηριστικών.

# ΚΕΦΑΛΑΙΟ 5

## ΘΕΩΡΗΤΙΚΟ ΥΠΟΒΑΘΡΟ

---

- 5.1 EEG Σήματα
  - 5.2 Κλασική Φασματική Ανάλυση EEG και περιορισμοί
  - 5.3 Μη-Γραμμική θεώρηση και δυναμικά συστήματα
  - 5.4 Ανακατασκευή χώρου φάσεων (Phase-Space Reconstruction)
  - 5.5 Recurrence Plots: από τη γεωμετρία στη δομή
  - 5.6 Recurrence Quantification Analysis (RQA)
  - 5.7 Σχέση RQA, δυναμικής και γνωστικών διεργασιών
  - 5.8 Σύνοψη και σύνδεση με τη μεθοδολογία
- 

Το παρόν κεφάλαιο θεμελιώνει το θεωρητικό πλαίσιο της παρούσας διπλωματικής και ειδικότερα της *Recurrence Quantification Analysis (RQA)*, η οποία αποτελεί τον κεντρικό άξονα της προτεινόμενης μεθοδολογίας. Η δομή του κεφαλαίου είναι σκόπιμα «κατευθυντική»: ξεκινά από τη φύση των EEG σημάτων και τους λόγους που καθιστούν την ανάλυσή τους δύσκολη, συνεχίζει με τις κλασικές φασματικές προσεγγίσεις και τα όριά τους, εισάγει τη μη-γραμμική θεώρηση του EEG ως εκδήλωση δυναμικού συστήματος, και καταλήγει στο κρίσιμο βήμα της ανακατασκευής του χώρου φάσεων. Πάνω σε αυτή τη γεωμετρική αναπαράσταση στηρίζονται τα *Recurrence Plots*, τα οποία λειτουργούν ως «γέφυρα» προς την RQA: την ποσοτική, συστηματική και ερμηνεύσιμη περιγραφή της δυναμικής δομής ενός σήματος.

Η επιλογή της RQA δεν αντιμετωπίζεται εδώ ως απλός εναλλακτικός εξαγωγέας χαρακτηριστικών, αλλά ως ένα ενιαίο θεωρητικό πλαίσιο για την αποτύπωση της οργάνωσης, της προβλεψιμότητας, της παραμονής σε καταστάσεις και της πολυπλοκότητας της εγκεφαλικής δραστηριότητας. Με αυτόν τον τρόπο, η εργασία μετατοπίζει το ενδιαφέρον από «μέσες» ή «στατικές» περιγραφές (π.χ. band-power) προς δομικά χαρακτηριστικά που κωδικοποιούν πώς εξελίσσεται το σύστημα στον χρόνο.

## 5.1 EEG Σήματα

Η ηλεκτροεγκεφαλογραφία (Electroencephalography, EEG) αποτελεί μία από τις πλέον διαδεδομένες μη επεμβατικές μεθόδους καταγραφής της εγκεφαλικής δραστηριότητας, παρέχοντας υψηλή χρονική ανάλυση και πρόσβαση στη δυναμική λειτουργία του εγκεφάλου. Τα EEG σήματα καταγράφουν μεταβολές του ηλεκτρικού δυναμικού στην επιφάνεια του κρανίου, οι οποίες προκύπτουν από τη συλλογική δραστηριότητα μεγάλων πληθυσμών νευρώνων και τη χωρική/αγώγιμη διάδοση των πεδίων μέσα από ιστούς με διαφορετικές ιδιότητες.

Ένα EEG σήμα μπορεί να θεωρηθεί ως διακριτή χρονοσειρά

$$x[n], \quad n = 1, 2, \dots, N,$$

η οποία προκύπτει από δειγματοληψία ενός συνεχούς σήματος  $x(t)$  με συχνότητα δειγματοληψίας  $f_s$ . Κάθε δείγμα αντιστοιχεί στη διαφορά δυναμικού μεταξύ ενός ηλεκτροδίου και ενός σημείου αναφοράς. Η μαθηματική αυτή αναπαράσταση επιτρέπει την εφαρμογή εργαλείων επεξεργασίας σήματος, ωστόσο η ερμηνεία απαιτεί προσοχή: το EEG είναι έμμεση, θορυβώδης και μεικτή αποτύπωση της υποκείμενης νευρωνικής δραστηριότητας.

### 5.1.1 Ιδιότητες EEG σημάτων και επιπτώσεις στην ανάλυση

Τα EEG σήματα χαρακτηρίζονται από ιδιότητες που καθιστούν την ανάλυσή τους ιδιαίτερα απαιτητική:

**Χαμηλός λόγος σήματος προς θόρυβο.** Το χρήσιμο σήμα είναι μικρού πλάτους και επηρεάζεται από ενδογενείς/εξωγενείς πηγές θορύβου (EMG, EOG, κινήσεις,

ηλεκτρικές παρεμβολές). Αυτό δυσχεραίνει την εξαγωγή σταθερών χαρακτηριστικών, ειδικά όταν οι γνωστικές μεταβολές είναι υποτίμητες.

**Μη-στασιμότητα.** Τα στατιστικά χαρακτηριστικά του EEG μεταβάλλονται στον χρόνο, καθώς το σύστημα ανταποκρίνεται σε αλλαγές της φυσιολογικής και γνωστικής κατάστασης. Σε πρωτόκολλα γνωστικού φορτίου (π.χ. mental arithmetic), η δυναμική μπορεί να αλλάζει γρήγορα, άρα η υπόθεση στασιμότητας σε μεγάλα παράθυρα είναι συχνά προβληματική.

**Μη-γραμμική δυναμική και πολυπλοκότητα.** Η εγκεφαλική δραστηριότητα προκύπτει από μη-γραμμικές αλληλεπιδράσεις νευρωνικών πληθυσμών. Ως αποτέλεσμα, η συμπεριφορά του συστήματος δεν περιγράφεται πλήρως από γραμμικά μοντέλα, ούτε από περιγραφές που αγνοούν τη δομή της χρονικής εξέλιξης.

**Δια-υποκειμενική μεταβλητότητα και αγωγή όγκου.** Οι διαφορές μεταξύ συμμετεχόντων (ανατομία, αγωγιμότητα, στρατηγικές εκτέλεσης, κόπωση) επηρεάζουν σημαντικά το EEG. Επιπλέον, η αγωγή όγκου οδηγεί σε μίξη πηγών μεταξύ καναλιών, μειώνοντας την ανεξαρτησία των χωρικών πληροφοριών και επιβάλλοντας προσεκτική ερμηνεία.

Οι παραπάνω ιδιότητες υποδεικνύουν ότι το EEG δεν μπορεί να αντιμετωπιστεί επαρκώς ως απλή γραμμική και στάσιμη χρονοσειρά. Αυτό αποτελεί το πρώτο βήμα στη λογική που οδηγεί σε εργαλεία μη-γραμμικής δυναμικής και τελικά στη RQA.

## 5.2 Κλασική Φασματική Ανάλυση EEG και περιορισμοί

Η φασματική ανάλυση αποσκοπεί στη μελέτη της κατανομής της ενέργειας ενός σήματος στο πεδίο της συχνότητας. Υπό την υπόθεση ότι το σήμα είναι (κατά προσέγγιση) στάσιμο εντός ενός χρονικού παραθύρου, μπορεί να αναπαρασταθεί ως γραμμικός συνδυασμός ημιτονοειδών συνιστωσών. Ο διακριτός μετασχηματισμός Fourier (DFT) ορίζεται ως:

$$X[k] = \sum_{n=0}^{N-1} x[n] e^{-j\frac{2\pi}{N}kn}, \quad k = 0, \dots, N-1,$$

με διακριτές συχνότητες  $f_k = \frac{k}{N}f_s$  και φασματική ισχύ:

$$P[k] = |X[k]|^2.$$

Στην EEG βιβλιογραφία, η φασματική ανάλυση συνδέεται συχνά με μετρικές ισχύος σε προκαθορισμένες ζώνες ( $\delta, \theta, \alpha, \beta, \gamma$ ), καθώς και με χρονικοσυχνοτικές προσεγγίσεις (π.χ. STFT, wavelets) για μερική αντιμετώπιση της μη-στασιμότητας. Παρότι οι προσεγγίσεις αυτές είναι ισχυρές και ερμηνεύσιμες, εμφανίζουν δύο κρίσιμους περιορισμούς για το πρόβλημα της παρούσας εργασίας.

Πρώτον, ακόμη και σε χρονικοσυχνοτικές αναπαραστάσεις, το βασικό σήμα συνοψίζεται συχνά μέσω στατιστικών (μέση ισχύς/ενέργεια), τα οποία αποτυπώνουν τι πόση ισχύς υπάρχει και όχι πώς οργανώνεται η δυναμική στον χρόνο. Δεύτερον, οι ζώνες συχνότητων είναι συχνά προκαθορισμένες και όχι βέλτιστες για κάθε dataset/υποκείμενο, ενώ η έντονη μεταβλητότητα μπορεί να μεταφέρει τη διακριτική πληροφορία εκτός των canonical ορίων. Οι παρατηρήσεις αυτές αποτελούν ισχυρό κίνητρο για δύο συμπληρωματικές κατευθύνσεις: (α) πιο προσαρμοστικές αναπαραστάσεις στο φασματικό πεδίο και (β) μεθόδους που αποτυπώνουν δομή δυναμικής πέρα από την ισχύ. Η δεύτερη κατεύθυνση είναι ακριβώς το έδαφος στο οποίο «πατά» η RQA.

### 5.3 Μη-Γραμμική θεώρηση και δυναμικά συστήματα

Η μη-γραμμική θεώρηση αντιμετωπίζει το EEG ως παρατήρηση ενός πολύπλοκου δυναμικού συστήματος. Ένα δυναμικό σύστημα περιγράφει την εξέλιξη μιας κατάστασης στον χρόνο σύμφωνα με νόμο εξέλιξης. Σε συνεχές χρόνο:

$$\dot{s}(t) = F(s(t)),$$

και σε διακριτό χρόνο:

$$s_{n+1} = F(s_n),$$

όπου  $s(t) \in \mathbb{R}^d$  είναι το διάνυσμα κατάστασης στον χώρο φάσεων και  $F(\cdot)$  η (ενδεχομένως μη-γραμμική) δυναμική.

Στην πράξη, το πλήρες  $s(t)$  δεν είναι προσβάσιμο. Το EEG αποτελεί παρατηρήσιμη προβολή:

$$x(t) = h(s(t)),$$

όπου  $h(\cdot)$  είναι συνάρτηση παρατήρησης που συνοψίζει και αναμιγνύει υποκείμενες διεργασίες. Επομένως, αν στόχος είναι η περιγραφή της δυναμικής δομής, απαιτείται ένας τρόπος να «ανακτήσουμε» γεωμετρικά στοιχεία της τροχιάς του συστήματος από τη μονοδιάστατη παρατήρηση. Αυτό οδηγεί στην ανακατασκευή του χώρου φάσεων.

## 5.4 Ανακατασκευή χώρου φάσεων (Phase-Space Reconstruction)

Η ανακατασκευή του χώρου φάσεων επιτρέπει τη μελέτη της δυναμικής ενός συστήματος ακόμη και όταν διαθέτουμε μόνο μία χρονοσειρά παρατήρησης. Η βασική ιδέα είναι ότι καθυστερημένα δείγματα του  $x(t)$  περιέχουν πληροφορία για την υποκείμενη κατάσταση και μπορούν να σχηματίσουν ένα διάνυσμα ενσωμάτωσης.

Για διακριτό σήμα  $x[n]$ , ορίζεται:

$$\mathbf{x}_i = [x[i], x[i + \tau], x[i + 2\tau], \dots, x[i + (m - 1)\tau]] \in \mathbb{R}^m,$$

όπου  $m$  είναι η διάσταση ενσωμάτωσης και  $\tau$  η χρονική καθυστέρηση. Το σύνολο  $\{\mathbf{x}_i\}$  σχηματίζει τροχιά σε  $m$ -διάστατο χώρο, ο οποίος μπορεί να διατηρεί τις βασικές τοπολογικές/δυναμικές ιδιότητες του αρχικού χώρου φάσεων.

### 5.4.1 Θεώρημα Takens και σημασία για EEG

Το θεώρημα Takens παρέχει θεωρητική θεμελίωση: υπό γενικές συνθήκες, για σύστημα διάστασης  $d$ , ένα embedding με

$$m \geq 2d + 1$$

μπορεί να είναι τοπολογικά ισοδύναμο με το αρχικό σύστημα. Στην πράξη, το  $d$  είναι άγνωστο και το EEG δεν είναι ιδανικά ντετερμινιστικό, ωστόσο η ανακατασκευή παραμένει ισχυρό εργαλείο για τη δημιουργία γεωμετρικής αναπαράστασης της δυναμικής.

### 5.4.2 Παράμετροι $\tau$ και $m$

Η επιλογή  $\tau$  και  $m$  επηρεάζει άμεσα τη γεωμετρία της ανακατασκευής. Μικρό  $\tau$  οδηγεί σε πολύ συσχετισμένες συνιστώσες (διάνυσμα «συμπιεσμένο»), ενώ πολύ

μεγάλο  $\tau$  μπορεί να αποσυντονίζει τη δομή. Τυπικές στρατηγικές περιλαμβάνουν επιλογή  $\tau$  με βάση το πρώτο ελάχιστο της αμοιβαίας πληροφορίας ή το σημείο όπου η αυτοσυσχέτιση πέφτει κάτω από ένα κατώφλι. Για το  $m$ , συχνά χρησιμοποιείται η μέθοδος False Nearest Neighbors (FNN) ώστε να βρεθεί διάσταση όπου μειώνονται οι «ψευδείς» γειτονίες λόγω προβολής.

Η ανακατασκευή είναι το απαραίτητο υπόβαθρο ώστε να ορίσουμε την έννοια επιστροφής (recurrence) του συστήματος σε παρόμοιες καταστάσεις, η οποία είναι το κεντρικό concept των Recurrence Plots και, τελικά, της RQA.

## 5.5 Recurrence Plots: από τη γεωμετρία στη δομή

Τα Recurrence Plots (RP) αποτυπώνουν πότε το σύστημα επιστρέφει σε παρόμοιες καταστάσεις στον ανακατασκευασμένο χώρο φάσεων. Δοθέντων των διανυσμάτων  $\mathbf{x}_i$ , ορίζεται ο πίνακας επαναφοράς:

$$R_{i,j} = \begin{cases} 1, & \|\mathbf{x}_i - \mathbf{x}_j\| \leq \varepsilon \\ 0, & \text{διαφορετικά} \end{cases}, \quad i, j = 1, \dots, N,$$

όπου  $\varepsilon$  είναι κατώφλι απόστασης και  $\|\cdot\|$  συνήθως η Ευκλείδεια νόρμα. Το RP είναι η οπτική απεικόνιση του  $R$ .

Η κύρια διαγώνιος  $i = j$  (line of identity) είναι πάντα 1 και συνήθως αγνοείται στις μετρικές, καθώς αντιστοιχεί στην ταυτοποίηση κατάστασης με τον εαυτό της.

### 5.5.1 Ποιοτική ερμηνεία μορφών στο RP

Η δομή ενός RP δεν είναι τυχαία· αντανακλά την υποκείμενη δυναμική.

**Διαγώνιες γραμμές.** Υποδεικνύουν ότι δύο τμήματα της τροχιάς εξελίσσονται με παρόμοιο τρόπο, άρα σχετίζονται με ντετερμινισμό/προβλεψιμότητα.

**Κατακόρυφες/οριζόντιες γραμμές.** Υποδεικνύουν παραμονή του συστήματος σε παρόμοια κατάσταση (laminar/trapping).

**Διάσπαρτη «κοκκώδης» υφή.** Συμβατή με πιο στοχαστική ή έντονα χαοτική συμπεριφορά.

### 5.5.2 Η κρίσιμη επιλογή του $\epsilon$

Η τιμή του  $\epsilon$  ελέγχει την πυκνότητα επαναφορών. Πολύ μικρό  $\epsilon$  οδηγεί σε αραιό RP και ασταθείς μετρικές, ενώ πολύ μεγάλο  $\epsilon$  «πνίγει» τη δομή. Συχνή πρακτική είναι η επιλογή  $\epsilon$  ώστε να επιτυγχάνεται προκαθορισμένο *Recurrence Rate* (σταθερή πυκνότητα), κάτι που βελτιώνει τη συγκρισιμότητα μεταξύ υποκειμένων/παραθύρων. Η συστηματική επιλογή παραμέτρων είναι κρίσιμη, διότι η RQA κληρονομεί τη γεωμετρία του RP.

Το RP προσφέρει ισχυρή ποιοτική εικόνα, όμως για μάθηση και σύγκριση απαιτούνται ποσοτικά χαρακτηριστικά. Αυτό είναι ακριβώς το αντικείμενο της RQA.

## 5.6 Recurrence Quantification Analysis (RQA)

Η Recurrence Quantification Analysis (RQA) είναι το εργαλείο που μετατρέπει τη δομική πληροφορία ενός RP σε ποσοτικές μετρικές οι οποίες περιγράφουν θεμελιώδεις ιδιότητες της δυναμικής. Εδώ η RQA αντιμετωπίζεται ως το βασικό αντικείμενο μελέτης του κεφαλαίου: παρέχει ένα «λεξιλόγιο» για να μιλήσουμε με ακρίβεια για οργάνωση, προβλεψιμότητα, παραμονή σε καταστάσεις και πολυπλοκότητα στο EEG.

### 5.6.1 RQA με απλά λόγια: τι μετράει και γιατί έχει νόημα

Μια διαισθητική ερμηνεία της RQA είναι η εξής: φανταζόμαστε ότι το EEG (μετά την ανακατασκευή) δημιουργεί μια τροχιά που «περιφέρεται» στον χώρο καταστάσεων. Κάποιες φορές η τροχιά επιστρέφει κοντά σε προηγούμενες θέσεις. Το RP είναι ο χάρτης αυτών των επιστροφών. Η RQA, στη συνέχεια, μετράει τι μορφή έχουν αυτές οι επιστροφές.

Αν οι επιστροφές τείνουν να σχηματίζουν μακριές διαγώνιες γραμμές, τότε το σύστημα επαναλαμβάνει παρόμοια μοτίβα εξέλιξης: αυτό σχετίζεται με μεγαλύτερη προβλεψιμότητα/ντετερμινισμό. Αν εμφανίζονται κατακόρυφες γραμμές, τότε το σύστημα «κολλάει» για κάποιο διάστημα σε παρόμοια κατάσταση: αυτό σχετίζεται με laminar συμπεριφορά και χρόνους παραμονής. Αν, αντίθετα, οι επιστροφές είναι διάσπαρτες και χωρίς δομές, η δυναμική είναι λιγότερο οργανωμένη ή πιο στοχαστική.

Σε προβλήματα γνωστικού φορτίου, όπως rest vs mental arithmetic, το κρίσιμο δεν είναι μόνο αν αλλά πώς αλλάζει η δραστηριότητα: η RQA είναι χρήσιμη διότι «βλέπει» τη δομή της χρονικής οργάνωσης και όχι μόνο το μέσο επίπεδο ισχύος.

### 5.6.2 Τυπικοί ορισμοί: γραμμές, κατανομές και μετρικές

Οι μετρικές RQA βασίζονται κυρίως σε κατανομές μηκών γραμμικών δομών στο RP. Ορίζουμε:

**Διαγώνιες γραμμές.** Μια διαγώνια γραμμή μήκους  $l$  αντιστοιχεί σε συνεχόμενα 1s κατά μήκος  $i - j = \text{const}$ .

**Κατακόρυφες γραμμές.** Μια κατακόρυφη γραμμή μήκους  $v$  αντιστοιχεί σε συνεχόμενα 1s σε σταθερό  $j$  και μεταβαλλόμενο  $i$  (ή αντίστοιχα οριζόντιες γραμμές λόγω συμμετρίας).

Έστω  $P(l)$  ο αριθμός διαγώνιων γραμμών μήκους  $l \geq l_{\min}$  και  $P(v)$  ο αριθμός κατακόρυφων γραμμών μήκους  $v \geq v_{\min}$ . Επίσης, έστω

$$p(l) = \frac{P(l)}{\sum_{l=l_{\min}}^{\infty} P(l)}$$

η κανονικοποιημένη κατανομή μηκών διαγώνιων γραμμών (αντίστοιχα για  $p(v)$ ).

### 5.6.3 Βασικές και συμπληρωματικές μετρικές RQA

Στην πράξη, η RQA παρέχει ένα σύνολο μετρικών, καθεμία από τις οποίες αποτυπώνει διαφορετική όψη της δυναμικής. Παρακάτω παρουσιάζονται οι βασικές (και μερικές ιδιαίτερα χρήσιμες συμπληρωματικές) μετρικές.

Οι μετρικές αυτές έχουν ιδιαίτερη αξία στην EEG ανάλυση διότι δεν συνοψίζουν απλώς «πόση ενέργεια υπάρχει», αλλά κωδικοποιούν μορφές οργάνωσης της δυναμικής. Για παράδειγμα, μεταβολές στον  $DET$  και στο  $ENTR$  μπορούν να υποδεικνύουν αλλαγές στον βαθμό προβλεψιμότητας και στη δομική πολυπλοκότητα, ενώ  $LAM$  και  $TT$  είναι ιδιαίτερα χρήσιμες όταν υπάρχουν φαινόμενα παραμονής/σταθεροποίησης σε καταστάσεις.

#### 5.6.4 Παράμετροι RQA και πρακτική σταθερότητα

Η RQA εξαρτάται από παραμέτρους που καθορίζουν τη γεωμετρία του RP και, κατ' επέκταση, τις μετρικές. Οι σημαντικότερες είναι: η διάσταση ενσωμάτωσης  $m$ , η καθυστέρηση  $\tau$ , το κατώφλι  $\varepsilon$ , η νόρμα απόστασης, καθώς και τα ελάχιστα μήκη γραμμών  $l_{\min}$  και  $v_{\min}$ .

Ιδιαίτερα κρίσιμη είναι η επιλογή του  $\varepsilon$ . Για συγκρίσεις μεταξύ υποκειμένων/παραθύρων, μια πρακτικά ισχυρή στρατηγική είναι να επιλέγεται  $\varepsilon$  ώστε να επιτυγχάνεται προκαθορισμένο  $RR$  (π.χ. 1%–5%), δηλαδή σταθερή πυκνότητα επαναφορών. Έτσι, μειώνεται η επίδραση διαφορών κλίμακας και αυξάνεται η συγκρισιμότητα. Επιπλέον, η κανονικοποίηση ανά κανάλι (π.χ.  $z$ -score) πριν την RQA διευκολύνει τη σταθερότερη επιλογή κατωφλίου, ειδικά όταν υπάρχουν σημαντικές διαφορές πλάτους μεταξύ υποκειμένων.

Τέλος, η επιλογή  $l_{\min}$  και  $v_{\min}$  λειτουργεί ως φίλτρο θορύβου: πολύ μικρές γραμμές μπορεί να προκύπτουν τυχαία, άρα η χρήση ελάχιστων μηκών ελέγχει την ευαισθησία της RQA σε στοχαστικές επαναφορές.

#### 5.6.5 Windowed RQA: αποτύπωση μη-στασιμότητας

Επειδή το EEG είναι μη-στάσιμο, συχνά ενδιαφέρει η δυναμική να μετριέται τοπικά. Η windowed RQA εφαρμόζει RQA σε διαδοχικά χρονικά παράθυρα, παράγοντας μια χρονική εξέλιξη μετρικών (π.χ.  $DET(t)$ ,  $ENTR(t)$ ). Με τον τρόπο αυτό, οι μετρικές δεν αποτελούν μόνο χαρακτηριστικά ταξινόμησης, αλλά και εργαλείο ερμηνείας μεταβάσεων (state changes), κάτι ιδιαίτερα σχετικό με γνωστικό φορτίο.

Μετρική	Ορισμός	Ερμηνεία
Recurrence Rate (RR)	$RR = \frac{1}{N^2} \sum_{i,j} R_{i,j}$	Πυκνότητα επαναφορών. «Πόσο συχνά» το σύστημα επιστρέφει κοντά σε προηγούμενες καταστάσεις.
Determinism (DET)	$DET = \frac{\sum_{l=l_{\min}}^{\infty} l P(l)}{\sum_{i,j} R_{i,j}}$	Ποσοστό επαναφορών που σχηματίζουν διαγώνιες δομές. Υψηλότερο $DET$ υποδηλώνει πιο οργανωμένη/προβλέψιμη εξέλιξη.
Average diagonal length (L)	$L = \frac{\sum_{l=l_{\min}}^{\infty} l P(l)}{\sum_{l=l_{\min}}^{\infty} P(l)}$	Μέσο μήκος διαγώνιων γραμμών. Συνδέεται με τη μέση διάρκεια «παρόμοιας εξέλιξης».
Longest diagonal line ( $L_{\max}$ )	$L_{\max} = \max\{l : P(l) > 0\}$	Μέγιστο μήκος διαγώνιας γραμμής (εκτός LOI). Συνδέεται με χρονικές κλίμακες επαναληψιμότητας.
Divergence (DIV)	$DIV = \frac{1}{L_{\max}}$	Χονδρικός δείκτης απόκλισης τροχιών (συχνά συζητείται ως proxy σχετικός με Lyapunov).
Laminarity (LAM)	$LAM = \frac{\sum_{v=v_{\min}}^{\infty} v P(v)}{\sum_{i,j} R_{i,j}}$	Ποσοστό επαναφορών σε κατακόρυφες δομές. Υψηλότερο $LAM$ υποδηλώνει τάση παραμονής σε καταστάσεις.
Trapping Time (TT)	$TT = \frac{\sum_{v=v_{\min}}^{\infty} v P(v)}{\sum_{v=v_{\min}}^{\infty} P(v)}$	Μέσο μήκος κατακόρυφων γραμμών. «Πόσο χρόνο» παραμένει το σύστημα σε παρόμοια κατάσταση.
Entropy (ENTR)	$ENTR = - \sum_{l=l_{\min}}^{\infty} p(l) \log p(l)$	Πολυπλοκότητα διαγώνιας δομής. Υψηλότερες τιμές υποδηλώνουν μεγαλύτερη ποικιλία δομών.

## 5.7 Σχέση RQA, δυναμικής και γνωστικών διεργασιών

Οι γνωστικές διεργασίες, όπως η νοητική αριθμητική, συνοδεύονται από μεταβολές στη λειτουργική οργάνωση του εγκεφάλου. Οι μεταβολές αυτές δεν εκδηλώνονται μόνο ως αλλαγές στο φασματικό περιεχόμενο, αλλά επηρεάζουν τη συνολική δυναμική συμπεριφορά του συστήματος: δηλαδή, τον τρόπο με τον οποίο η δραστηριότητα εξελίσσεται και οργανώνεται στον χρόνο.

Η μη-γραμμική θεώρηση επιτρέπει να εξεταστούν αυτές οι μεταβολές στο επίπεδο δομής της δυναμικής. Σε αυτό το πλαίσιο, οι μετρικές RQA λειτουργούν ως ποσοτικοί δείκτες διαφορετικών «όψεων» της οργάνωσης. Για παράδειγμα, μια αύξηση στον *DET* μπορεί να υποδηλώνει πιο οργανωμένη ή προβλέψιμη εξέλιξη στο ανακατασκευασμένο δυναμικό τοπίο, ενώ μια μεταβολή στον *ENTR* μπορεί να αντικατοπτρίζει αλλαγή στο εύρος και την ποικιλία των δυναμικών μοτίβων. Αντίστοιχα, οι δείκτες *LAM* και *TT* συνδέονται με την τάση παραμονής σε καταστάσεις, η οποία μπορεί να σχετίζεται με «σταθεροποίηση» της δραστηριότητας ή με αλλαγές σε καθεστώτα λειτουργικής οργάνωσης.

Σημαντικό είναι ότι οι RQA μετρικές δεν ανταγωνίζονται τις φασματικές περιγραφές, αλλά τις συμπληρώνουν: οι φασματικές μετρικές περιγράφουν το περιεχόμενο σε συχνότητες, ενώ η RQA περιγράφει τη δομή της χρονικής οργάνωσης και την γεωμετρία της δυναμικής. Αυτό ακριβώς δικαιολογεί τη χρήση της RQA ως βασικού θεωρητικού άξονα της παρούσας εργασίας, ειδικά όταν ο στόχος είναι η διάκριση γνωστικών καταστάσεων με αυξημένες απαιτήσεις γενίκευσης.

## 5.8 Σύνοψη και σύνδεση με τη μεθοδολογία

Συνοψίζοντας, το κεφάλαιο ανέδειξε ότι το EEG χαρακτηρίζεται από μη-στασιμότητα, θόρυβο, μεταβλητότητα και μη-γραμμική δυναμική, στοιχεία που περιορίζουν την επάρκεια καθαρά γραμμικών/στατικών περιγραφών. Η μη-γραμμική θεώρηση επιτρέπει τη μοντελοποίηση της εγκεφαλικής δραστηριότητας ως δυναμικού συστήματος, ενώ η ανακατασκευή χώρου φάσεων παρέχει το γεωμετρικό πλαίσιο για να οριστεί η έννοια της επαναφοράς. Τα Recurrence Plots εισάγουν την ποιοτική δομή της δυναμικής και η Recurrence Quantification Analysis (RQA) μετασχηματίζει αυτή τη δομή σε ποσοτικές, ερμηνεύσιμες μετρικές που μπορούν να αξιοποιηθούν συστηματικά.

Στα επόμενα κεφάλαια, η θεωρητική αυτή βάση μεταφράζεται σε συγκεκριμένες υπολογιστικές επιλογές: (i) τρόπο προεπεξεργασίας και σταθεροποίησης της κλίμακας, (ii) ορισμό παραμέτρων embedding και κατωφλίου  $\epsilon$  με συστηματικό τρόπο, και (iii) εξαγωγή RQA χαρακτηριστικών (ενδεχομένως ανά παράθυρο) ως κεντρικό κομμάτι του feature set που τροφοδοτεί το τελικό ταξινομητικό pipeline.

# ΚΕΦΑΛΑΙΟ 6

## ΣΥΝΟΛΟ ΔΕΔΟΜΕΝΩΝ ΚΑΙ ΜΕΘΟΔΟΛΟΓΙΑ

- 
- 6.1 Σύνολο δεδομένων και πειραματικό πρωτόκολλο
  - 6.2 Προεπεξεργασία και οργάνωση δεδομένων
  - 6.3 Ανακάλυψη/επιλογή ζωνών συχνότητας και φιλτράρισμα
  - 6.4 Εξαγωγή μη-γραμμικών χαρακτηριστικών με RQA
  - 6.5 Σύνηξη χαρακτηριστικών και ταξινόμηση
  - 6.6 Υλοποίηση και αναπαραγωγιμότητα
- 

Το παρόν κεφάλαιο περιγράφει το σύνολο δεδομένων και τη μεθοδολογική προσέγγιση που ακολουθείται για την ανάλυση και ταξινόμηση EEG σημάτων σε συνθήκες διαφορετικού γνωστικού φορτίου. Πριν την παρουσίαση του dataset, είναι χρήσιμο να συνοψιστεί σαφώς το πρόβλημα που επιλύεται και η στρατηγική που ακολουθείται.

Δεδομένων πολυκαναλικών καταγραφών EEG από δύο πειραματικές συνθήκες, ηρεμία (*resting state*) και νοητική αριθμητική (*mental arithmetic*), ο στόχος είναι η αυτόματη διάκριση των δύο καταστάσεων, δηλαδή η κατασκευή ενός μοντέλου που λαμβάνει ως είσοδο ένα χρονικό τμήμα EEG και προβλέπει σε ποια από τις δύο συνθήκες αντιστοιχεί. Το πρόβλημα είναι ουσιαστικά ένα δυαδικό πρόβλημα ταξινόμησης, αλλά με αυξημένη δυσκολία λόγω (i) μη-στασιμότητας του EEG, (ii) πιθανής υπολειπόμενης παρουσίας artifacts και (iii) έντονης δια-υποκειμενικής μεταβλητότητας, που καθιστά κρίσιμη τη γενίκευση σε νέο συμμετέχοντα.

Η προσέγγιση της παρούσας εργασίας οργανώνεται ως ένα αναπαραγωγίμο υπολογιστικό pipeline. Συνοπτικά, οι καταγραφές: (α) προεπεξεργάζονται και οργανώνονται σε τυποποιημένα παράθυρα ανάλυσης, (β) αποσυντίθενται σε ζώνες συχνοτήτων (κλασικές και/ή προσαρμοστικές), (γ) περιγράφονται με μη-γραμμικά χαρακτηριστικά δυναμικής μέσω Recurrence Quantification Analysis (RQA), και (δ) τα χαρακτηριστικά συντίθενται σε ενιαία αναπαράσταση, πάνω στην οποία εκπαιδεύονται επιβλεπόμενα μοντέλα μηχανικής μάθησης. Η αξιολόγηση γίνεται με αυστηρή στρατηγική ανά υποκείμενο (π.χ. LOSO), ώστε τα αποτελέσματα να αντανακλούν ρεαλιστική χρήση σε νέο άτομο.

Αρχικά παρουσιάζεται το δημόσια διαθέσιμο dataset EEGMAT και το πειραματικό πρωτόκολλο καταγραφής. Στη συνέχεια περιγράφονται αναλυτικά τα βήματα του pipeline. Ιδιαίτερη έμφαση δίνεται στην προεπεξεργασία και την οργάνωση των δεδομένων, καθώς αυτές οι επιλογές καθορίζουν την ποιότητα των χαρακτηριστικών και την εγκυρότητα της αξιολόγησης. Έτσι, μετά την περιγραφή του dataset, το επόμενο τμήμα (section 6.2) παρουσιάζει τη **Προεπεξεργασία και οργάνωση δεδομένων**, δηλαδή το πώς οι καταγραφές μετατρέπονται σε κατάλληλες μονάδες ανάλυσης για εξαγωγή χαρακτηριστικών και εκπαίδευση μοντέλων.

## 6.1 Σύνολο δεδομένων και πειραματικό πρωτόκολλο

Στην παρούσα εργασία χρησιμοποιείται το δημόσια διαθέσιμο σύνολο δεδομένων EEGMAT (Electroencephalograms during Mental Arithmetic Task Performance), το οποίο περιλαμβάνει καταγραφές ΗΕΓ κατά την εκτέλεση έντονου γνωστικού έργου νοητικής αριθμητικής (serial subtraction), καθώς και καταγραφές κατάστασης ηρεμίας (resting state) για σκοπούς σύγκρισης [29]. Το συγκεκριμένο dataset επιλέγεται λόγω της καθαρής αντιπαραβολής δύο διακριτών συνθηκών (ηρεμία έναντι γνωστικού έργου), αλλά και επειδή παρέχει επαρκείς πληροφορίες για τη διάταξη καναλιών, τις παραμέτρους καταγραφής και τα μεταδεδομένα συμμετεχόντων.

Για την ορθή ερμηνεία και αξιοποίηση του EEGMAT, είναι απαραίτητο να διευκρινιστούν: (α) τα χαρακτηριστικά του πληθυσμού, (β) η διαδικασία καταγραφής και (γ) η δομή των διαθέσιμων τμημάτων EEG ανά συμμετέχοντα.

### 6.1.1 Πληθυσμός και ομάδες

Το τελικό δείγμα του EEGMAT περιλαμβάνει καταγραφές από **36** συμμετέχοντες, καθώς μέρος των αρχικών συμμετεχόντων αποκλείστηκε λόγω χαμηλής ποιότητας σήματος, όπως έντονα οφθαλμογραφικά ή μυογραφικά artifacts. Επιπλέον, στο dataset παρέχεται ομαδοποίηση των συμμετεχόντων σε δύο ομάδες (**G** και **B**) βάσει της επίδοσής τους στη νοητική αριθμητική, μέσω του δείκτη *count quality*, όπως αυτός ορίζεται από τους δημιουργούς του dataset. Στην παρούσα εργασία, τα labels αυτά μπορούν να αξιοποιηθούν είτε για ανάλυση απόδοσης (G/B), είτε αποκλειστικά ως συμπληρωματική μετα-πληροφορία, ανάλογα με το εκάστοτε πειραματικό ερώτημα.

Η ύπαρξη ομάδων επίδοσης επιτρέπει, πέρα από τη βασική διάκριση συνθηκών (rest vs. task), και πιθανές επεκτάσεις προς πιο λεπτές αναλύσεις, όπως η διερεύνηση σχέσης δυναμικών δεικτών με τη γνωστική απόδοση.

### 6.1.2 Συνθήκες καταγραφής και ηλεκτρόδια

Η καταγραφή πραγματοποιήθηκε με **μονοπολικό σύστημα 23 καναλιών**, με τοποθέτηση ηλεκτροδίων σύμφωνα με το διεθνές σύστημα **10–20** (π.χ. Fp1/Fp2, F3/F4/Fz, C3/C4/Cz, P3/P4/Pz, O1/O2, T3/T4/T5/T6 κ.ά.) και αναφορά στα συνδεδεμένα ηλεκτρόδια των λοβών των ωτών [29]. Η συχνότητα δειγματοληψίας είναι  $f_s = 500$  Hz, ενώ κατά την καταγραφή εφαρμόστηκαν φίλτρα υψηλής διέλευσης στα 0.5 Hz, χαμηλής διέλευσης στα 45 Hz και φίλτρο απόρριψης θορύβου δικτύου στα 50 Hz.

Οι παραπάνω ρυθμίσεις καταγραφής είναι τυπικές για πρωτόκολλα EEG που στοχεύουν στη μελέτη γνωστικών διεργασιών, καθώς περιορίζουν χαμηλοσυχνοτικές μετατοπίσεις και υψηλοσυχνοτικό θόρυβο, διατηρώντας παράλληλα τις κλασικές ζώνες EEG που σχετίζονται με γνωστική επεξεργασία.

### 6.1.3 Διαθέσιμα τμήματα EEG ανά συμμετέχοντα

Για κάθε συμμετέχοντα, το σύνολο δεδομένων EEGMAT περιλαμβάνει τμήματα EEG τα οποία έχουν ήδη ελεγχθεί και χαρακτηριστεί ως απαλλαγμένα από εμφανή artifacts. Τα τμήματα αυτά αντιστοιχούν σε δύο διακριτές πειραματικές συνθήκες.

Η πρώτη συνθήκη αφορά την κατάσταση ηρεμίας (*resting state*), κατά την οποία οι συμμετέχοντες βρίσκονται με κλειστά μάτια και δεν εκτελούν κάποιο γνωστικό έργο. Για τη συνθήκη αυτή παρέχεται καταγραφή συνολικής διάρκειας 180 δευτερο-

λέπτων. Η δεύτερη συνθήκη αφορά τη νοητική αριθμητική (*mental counting*), κατά την οποία οι συμμετέχοντες εκτελούν σειριακές αφαιρέσεις. Για τη συνθήκη αυτή παρέχεται καταγραφή διάρκειας 60 δευτερολέπτων, η οποία αντιστοιχεί στην αρχική φάση εκτέλεσης του έργου, όπου το γνωστικό φορτίο είναι αυξημένο.

Τα δεδομένα παρέχονται σε μορφή αρχείων EDF, τα οποία περιλαμβάνουν τόσο τα σήματα EEG όσο και πληροφορίες σχετικά με τη διάταξη των καναλιών και τη συχνότητα δειγματοληψίας. Επιπλέον, το σύνολο δεδομένων συνοδεύεται από αρχεία μεταδεδομένων, τα οποία περιέχουν πληροφορίες για τους συμμετέχοντες και το πειραματικό πρωτόκολλο.

Με βάση τη δομή αυτή, το επόμενο βήμα είναι η διαμόρφωση των καταγραφών σε μορφή κατάλληλη για εξαγωγή χαρακτηριστικών και στατιστική σύγκριση, μέσω συστηματικής προεπεξεργασίας και οργάνωσης των δεδομένων.

## 6.2 Προεπεξεργασία και οργάνωση δεδομένων

Στόχος της διαδικασίας προεπεξεργασίας είναι η δημιουργία ενός συνεκτικού και αξιόπιστου συνόλου δεδομένων, κατάλληλου για περαιτέρω ανάλυση με μη-γραμμικές μεθόδους. Πρωταρχικός στόχος είναι η εξασφάλιση συγκρίσιμων δειγμάτων μεταξύ διαφορετικών πειραματικών συνθηκών, η ελαχιστοποίηση της επίδρασης θορύβου και ακραίων τιμών, καθώς και η διαμόρφωση εισόδων κατάλληλων για την ανακατασκευή χώρου φάσεων και την εξαγωγή χαρακτηριστικών.

Αρχικά, πραγματοποιείται φόρτωση των αρχείων EDF και έλεγχος της διάταξης των καναλιών, ώστε να διασφαλιστεί ότι όλα τα σήματα παρουσιάζουν συνεπή αντιστοίχιση καναλιών μεταξύ των συμμετεχόντων. Η διαδικασία αυτή είναι απαραίτητη για την αποφυγή σφαλμάτων κατά τη σύγκριση και τη σύντηξη χαρακτηριστικών.

Στη συνέχεια, επιλέγονται τα διαθέσιμα τμήματα EEG για κάθε πειραματική συνθήκη, όπως αυτά παρέχονται από το dataset. Όταν απαιτείται άμεση σύγκριση μεταξύ συνθηκών, επιλέγονται τμήματα ίσης χρονικής διάρκειας, ώστε να αποφεύγεται μεροληψία που σχετίζεται με τη διαφορετική διάρκεια καταγραφής.

Προαιρετικά, εφαρμόζεται κανονικοποίηση τύπου z-score ανά κανάλι, με σκοπό τη μείωση της επίδρασης διαφορών κλίμακας μεταξύ καναλιών και συμμετεχόντων. Η κανονικοποίηση αυτή επιτρέπει την πιο σταθερή εξαγωγή χαρακτηριστικών, ιδιαίτερα όταν συνδυάζονται δεδομένα από πολλαπλά κανάλια.

Τέλος, όπου κρίνεται σκόπιμο, τα σήματα μπορούν να τμηματοποιηθούν σε χρονικά παράθυρα σταθερού μήκους, με ή χωρίς επικάλυψη. Η τμηματοποίηση αυτή αυξάνει τον αριθμό διαθέσιμων δειγμάτων και επιτρέπει τη μελέτη της χρονικής μεταβλητότητας της εγκεφαλικής δραστηριότητας. Παράλληλα, είναι ιδιαίτερα χρήσιμη όταν επιδιώκεται αξιολόγηση μοντέλων με περισσότερα παραδείγματα, διατηρώντας την πληροφορία σε ρεαλιστική χρονική κλίμακα.

Αφού τα δεδομένα οργανωθούν σε κατάλληλη μορφή, το επόμενο βήμα είναι η ανάλυση σε ζώνες συχνοτήτων, καθώς οι επιδράσεις του γνωστικού φορτίου συχνά εντοπίζονται σε συγκεκριμένες συχνοτικές περιοχές.

### **6.3 Ανακάλυψη/επιλογή ζωνών συχνοτήτων και φιλτράρισμα**

Λόγω της έντονης μη-στασιμότητας των EEG σημάτων, η ανάλυση στο πεδίο της συχνότητας και ειδικότερα η αποσύνθεση σε επιμέρους ζώνες συχνοτήτων αποτελεί κρίσιμο στάδιο της μεθοδολογίας. Οι μεταβολές που σχετίζονται με το γνωστικό φορτίο δεν εκδηλώνονται απαραίτητα ομοιόμορφα σε όλο το φάσμα, αλλά ενδέχεται να εντοπίζονται σε συγκεκριμένες συχνοτικές περιοχές.

Στο πλαίσιο της παρούσας εργασίας, οι ζώνες συχνοτήτων μπορούν είτε να οριστούν με βάση την κλασική βιβλιογραφία (π.χ.  $\delta$ ,  $\theta$ ,  $\alpha$ ,  $\beta$ ,  $\gamma$ ), είτε να προκύψουν μέσω δεδομενοκεντρικής διαδικασίας ανακάλυψης ζωνών. Η δεύτερη προσέγγιση επιτρέπει τον προσαρμοστικό καθορισμό των ορίων των ζωνών, με βάση τα χαρακτηριστικά του συγκεκριμένου συνόλου δεδομένων και της πειραματικής συνθήκης.

Μετά τον καθορισμό των ζωνών συχνοτήτων, εφαρμόζεται φιλτράρισμα τύπου band-pass ανά κανάλι και ανά ζώνη. Το αποτέλεσμα είναι η δημιουργία επιμέρους χρονοσειρών που αντιστοιχούν σε συγκεκριμένες συχνοτικές περιοχές, οι οποίες χρησιμοποιούνται στη συνέχεια για την εξαγωγή μη-γραμμικών χαρακτηριστικών.

Με τον τρόπο αυτό, η μη-γραμμική ανάλυση δεν εφαρμόζεται στο ακατέργαστο EEG ως ενιαία χρονοσειρά, αλλά σε αποσυντεθειμένες συνιστώσες που ενδέχεται να αντανακλούν διαφορετικούς νευροφυσιολογικούς μηχανισμούς. Στη συνέχεια περιγράφεται η διαδικασία εξαγωγής χαρακτηριστικών μέσω RQA.

## 6.4 Εξαγωγή μη-γραμμικών χαρακτηριστικών με RQA

Για την ποσοτική περιγραφή της δυναμικής δομής των EEG σημάτων χρησιμοποιείται η Recurrence Quantification Analysis (RQA). Η RQA βασίζεται στην ανάλυση της επανεμφάνισης παρόμοιων καταστάσεων του συστήματος στον ανακατασκευασμένο χώρο φάσεων, ο οποίος προκύπτει μέσω χρονικής ενσωμάτωσης.

Δοθέντος ενός διακριτού σήματος  $x[n]$ , σχηματίζονται διανύσματα ενσωμάτωσης που περιλαμβάνουν χρονικά καθυστερημένα δείγματα του σήματος. Τα διανύσματα αυτά χρησιμοποιούνται για τον υπολογισμό του πίνακα επαναφοράς, ο οποίος κωδικοποιεί αν δύο καταστάσεις του συστήματος βρίσκονται εντός ενός προκαθορισμένου κατωφλίου απόστασης. Η επιλογή των παραμέτρων ενσωμάτωσης (διάσταση  $m$ , καθυστέρηση  $\tau$ ) και του κατωφλίου  $\varepsilon$  καθορίζει τη γεωμετρία του recurrence plot και επηρεάζει άμεσα τις παραγόμενες μετρικές.

Από τον πίνακα επαναφοράς εξάγονται μετρικές RQA που συνοψίζουν τη γεωμετρική και χρονική δομή της δυναμικής συμπεριφοράς. Στην παρούσα εργασία χρησιμοποιούνται ενδεικτικά δείκτες όπως ο Recurrence Rate, ο οποίος εκφράζει την πυκνότητα επαναφοράς, ο Determinism που σχετίζεται με τον βαθμό προβλεψιμότητας, η Laminarity που αποτυπώνει καταστάσεις παγίδευσης και η Entropy που ποσοτικοποιεί την πολυπλοκότητα της δυναμικής.

Οι δείκτες αυτοί υπολογίζονται ανά κανάλι και, όπου εφαρμόζεται φασματικός διαχωρισμός, ανά ζώνη συχνοτήτων, σχηματίζοντας ένα πολυδιάστατο διάνυσμα χαρακτηριστικών για κάθε δείγμα ή χρονικό παράθυρο. Το τελικό σύνολο χαρακτηριστικών προκύπτει από τη σύντηξη πληροφορίας πολλών καναλιών/ζωνών και χρησιμοποιείται ως είσοδος σε μοντέλα ταξινόμησης, όπως περιγράφεται στην επόμενη ενότητα.

## 6.5 Σύντηξη χαρακτηριστικών και ταξινόμηση

Τα χαρακτηριστικά RQA που προκύπτουν από διαφορετικά κανάλια και ζώνες συχνοτήτων συντίθενται σε ένα ενιαίο διάνυσμα εισόδου, το οποίο χρησιμοποιείται για την εκπαίδευση μοντέλων επιβλεπόμενης μηχανικής μάθησης.

Η ταξινόμηση στοχεύει στη διάκριση μεταξύ διαφορετικών πειραματικών συνθηκών, όπως η κατάσταση ηρεμίας και η νοητική αριθμητική, καθώς και, όπου εξετάζεται, μεταξύ ομάδων διαφορετικής γνωστικής απόδοσης. Η εκπαίδευση των μο-

ντέλων πραγματοποιείται με τυπικές διαδικασίες διαχωρισμού δεδομένων, όπως train–test split ή διασταυρωμένη επικύρωση. Ιδιαίτερη μέριμνα λαμβάνεται ώστε να αποφεύγεται η διαρροή πληροφορίας μεταξύ παραθύρων που προέρχονται από τον ίδιο συμμετέχοντα, όταν εφαρμόζεται τμηματοποίηση, καθώς κάτι τέτοιο μπορεί να οδηγήσει σε υπερεκτίμηση της απόδοσης.

### 6.5.1 Μετρικές αξιολόγησης

Η απόδοση των μοντέλων αξιολογείται με καθιερωμένες μετρικές ταξινόμησης, όπως:

- Accuracy,
- Precision, Recall και F1-score,
- Πίνακας σύγχυσης (confusion matrix),
- προαιρετικά, ROC-AUC για δυαδική ταξινόμηση.

Οι μετρικές αυτές παρέχουν συμπληρωματική εικόνα της απόδοσης, ιδίως σε περιπτώσεις ανισορροπίας κλάσεων ή όταν ενδιαφέρει η συμπεριφορά του μοντέλου ανά κατηγορία.

## 6.6 Υλοποίηση και αναπαραγωγιμότητα

Η συνολική μεθοδολογία υλοποιείται ως ένα ολοκληρωμένο υπολογιστικό pipeline, το οποίο περιλαμβάνει διακριτά και σαφώς ορισμένα στάδια, από τη φόρτωση και οργάνωση του συνόλου δεδομένων έως την τελική αξιολόγηση των μοντέλων. Κάθε στάδιο υλοποιείται με τρόπο που επιτρέπει τον έλεγχο και την τροποποίηση των επιμέρους παραμέτρων, διευκολύνοντας τη συστηματική πειραματική διερεύνηση.

Για τη διασφάλιση της αναπαραγωγιμότητας, αποθηκεύονται ενδιάμεσα artifacts, όπως οι ορισμοί των ζωνών συχνότητων και οι πίνακες χαρακτηριστικών, ενώ καταγράφονται ρητά οι βασικές παράμετροι της ανάλυσης, όπως η διάσταση και η καθυστέρηση ενσωμάτωσης, το κατώφλι επαναφοράς και το μήκος των χρονικών παραθύρων. Η προσέγγιση αυτή επιτρέπει την επανάληψη των πειραμάτων και τη συστηματική αξιολόγηση εναλλακτικών ρυθμίσεων.

## ΚΕΦΑΛΑΙΟ 7

# ΥΛΟΠΟΙΗΣΗ ΚΑΙ ΑΝΑΠΑΡΑΓΩΓΙΜΟΤΗΤΑ

---

7.1 Επισκόπηση της υπολογιστικής ροής (pipeline)

7.2 Δομή κώδικα και ρόλοι αρχείων

7.3 Εξαγωγή χαρακτηριστικών

7.4 Σύνηξη χαρακτηριστικών: `fuse_features.py`

7.5 Εκπαίδευση και αξιολόγηση ταξινομητή: `train_classifier.py`

---

### 7.1 Επισκόπηση της υπολογιστικής ροής (pipeline)

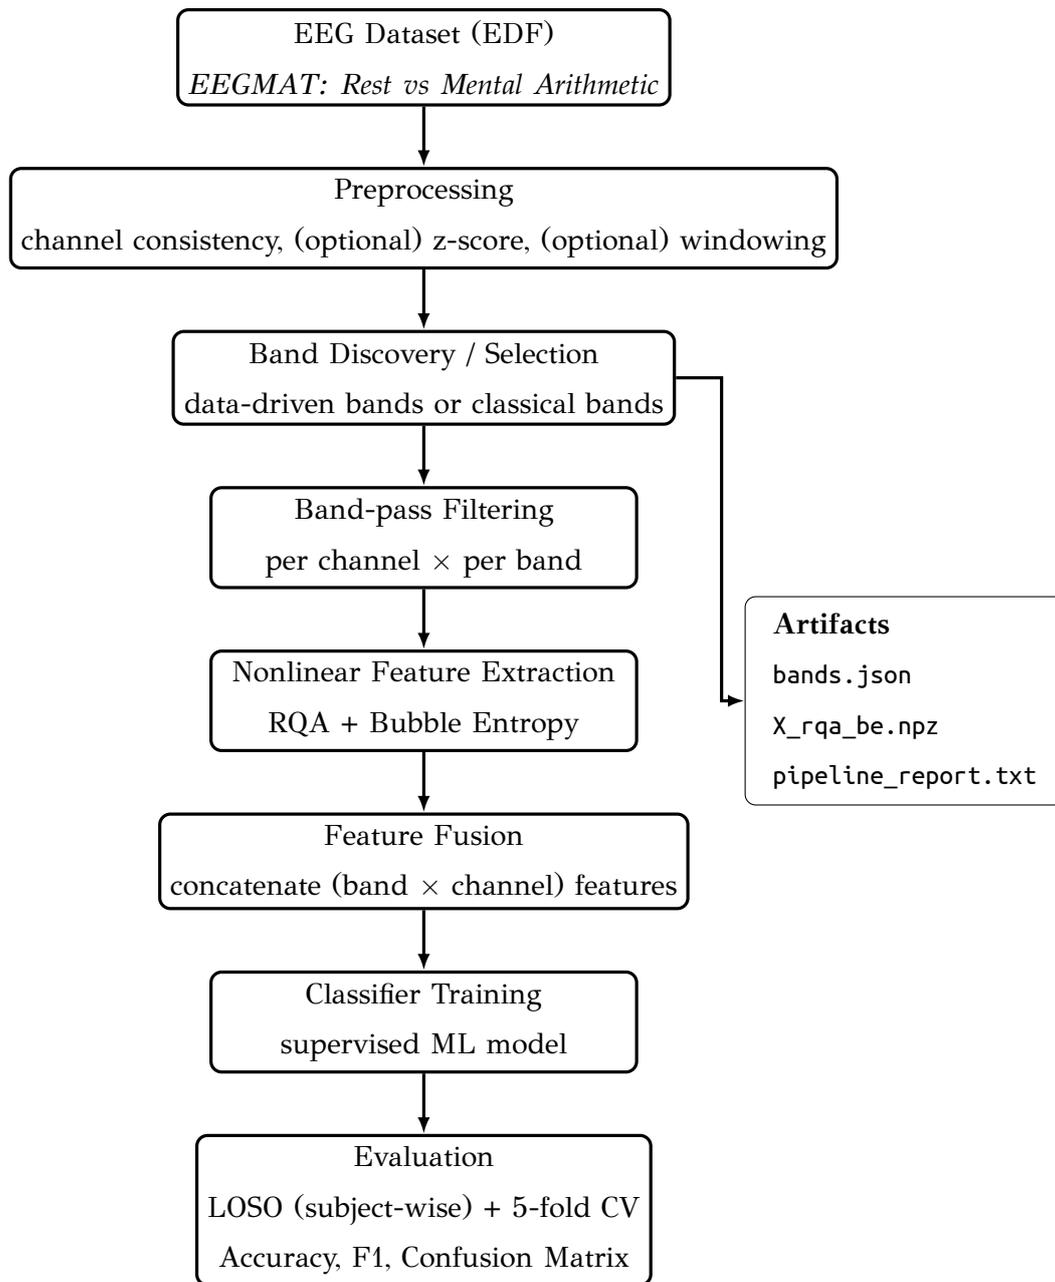
Η υλοποίηση της παρούσας διπλωματικής οργανώθηκε ως ένα αναπαραγώγιμο υπολογιστικό *pipeline* με σαφώς διακριτά στάδια, ώστε (i) να είναι εύκολη η επανάληψη των πειραμάτων με διαφορετικές παραμετροποιήσεις, (ii) να γίνεται αποθήκευση ενδιάμεσων αποτελεσμάτων (artifacts) και (iii) να αποφεύγονται σφάλματα ροής (π.χ. λάθος αντιστοίχιση καναλιών/συμμετεχόντων).

Σε υψηλό επίπεδο, η ροή περιλαμβάνει:

1. φόρτωση και οργάνωση των EEG καταγραφών (EDF/BIDS),
2. ανακάλυψη ή επιλογή ζωνών συχνοτήτων (bands),
3. φιλτράρισμα ανά ζώνη (band-pass) και παραγωγή band-specific χρονοσειρών,
4. εξαγωγή μη-γραμμικών χαρακτηριστικών (RQA) και συμπληρωματικών δεικτών (Bubble Entropy),

5. σύντηξη χαρακτηριστικών σε ενιαίο διάνυσμα ανά δείγμα,
6. εκπαίδευση και αξιολόγηση ταξινομητή,
7. αποθήκευση artifacts και καταγραφή παραμέτρων.

Η υλοποίηση έχει διαχωριστεί σε αρχεία Python, όπου κάθε αρχείο αντιστοιχεί σε ένα λειτουργικό στάδιο. Η κεντρική εκτέλεση/ενορχήστρωση γίνεται από το `run_pipeline.py`, ενώ τα επιμέρους στάδια υλοποιούνται στα: `load_data.py`, `preprocessing.py`, `band_discovery.py`, `filter_band.py`, `extract_rqa.py`, `utils_rqa.py`, `bubble_entropy.py`, `fuse_features.py`, `train_classifier.py`, και `config.py` για ρυθμίσεις/παραμέτρους.



Σχήμα 7.1: Συνολική ροή του προτεινόμενου υπολογιστικού pipeline για ανάλυση και ταξινόμηση EEG σημάτων. Τα σήματα προεπεξεργάζονται, αποσυντίθενται σε ζώνες συχνοτήτων (κλασικές ή/και δεδομενοκεντρικές), αναλύονται μέσω μη-γραμμικών δεικτών (RQA και Bubble Entropy), συντίθενται σε ενιαία αναπαράσταση και αξιολογούνται με subject-wise πρωτόκολλα.

## 7.2 Δομή κώδικα και ρόλοι αρχείων

### 7.2.1 Κεντρικός εντοπιστής: `run_pipeline.py`

Το `run_pipeline.py` λειτουργεί ως *driver script*. Εκτελεί σειριακά τα στάδια, δημιουργεί/διαχειρίζεται φάκελο artifacts και κρατά συνοπτική αναφορά (log/report). Πρακτικά, αποτελεί το σημείο όπου:

- ορίζονται paths του project (`PROJECT_ROOT`, `ARTIFACTS_DIR`),
- δηλώνονται τα αρχεία εξόδου (π.χ. `bands.json`, `X_rqa_be.npz`),
- καλούνται οι συναρτήσεις φόρτωσης δεδομένων, band discovery, φιλτραρίσματος, εξαγωγής χαρακτηριστικών, σύντηξης και εκπαίδευσης.

Σημαντικό στοιχείο αναπαραγωγιμότητας είναι ότι τα artifacts γράφονται σε σταθερή τοποθεσία, ώστε να μπορεί να γίνει (α) επανάληψη πειραμάτων και (β) έλεγχος των ενδιάμεσων αποτελεσμάτων χωρίς να χρειάζεται επανυπολογισμός κάθε φορά.

### 7.2.2 Φόρτωση δεδομένων: `load_data.py`

Η φόρτωση του EEGMAT υλοποιείται στο `load_data.py`. Ο βασικός σκοπός του module είναι:

- να εντοπίζει και να διαβάζει τα EDF αρχεία (ανά συμμετέχοντα και συνθήκη),
- να επιστρέφει δομές δεδομένων που είναι κατάλληλες για downstream επεξεργασία,
- να κρατά μετα-πληροφορία (π.χ. subject id, condition labels) με συνεπή τρόπο.

### 7.2.3 Προεπεξεργασία: `preprocessing.py`

Το `preprocessing.py` συγκεντρώνει τυπικές λειτουργίες προεπεξεργασίας όπως:

- έλεγχο συνέπειας καναλιών,
- (προαιρετική) κανονικοποίηση ανά κανάλι (π.χ. z-score),
- (προαιρετικά) τμηματοποίηση σε παράθυρα με/χωρίς επικάλυψη.

Ακόμη και όταν χρησιμοποιούνται ήδη artifact-free segments, η προεπεξεργασία είναι χρήσιμη ώστε η εξαγωγή χαρακτηριστικών να είναι σταθερή και συγκρίσιμη μεταξύ συμμετεχόντων. Ειδικά για RQA, η κλίμακα του σήματος επηρεάζει την επιλογή κατωφλίου  $\varepsilon$ , άρα η κανονικοποίηση βοηθά ώστε το  $\varepsilon$  να έχει πιο ομοιογενή ερμηνεία.

#### 7.2.4 Ανακάλυψη ζωνών συχνοτήτων: `band_discovery.py`

Το module `band_discovery.py` υλοποιεί μία *data-driven* διαδικασία για τον ορισμό ζωνών συχνοτήτων. Η λογική είναι ότι, αντί να επιβληθούν αυστηρά τα κλασικά όρια ( $\delta/\theta/\alpha/\beta/\gamma$ ), μπορούν να εξαχθούν όρια που αντανακλούν τη συγκεκριμένη καταγραφή/συνθήκη.

Τυπικά, η έξοδος αυτού του σταδίου είναι ένα σύνολο από **bands** (π.χ. λίστα από  $(f_{low}, f_{high})$ ), το οποίο αποθηκεύεται ως artifact (π.χ. `bands.json`) και επαναχρησιμοποιείται στο φιλτράρισμα.

#### 7.2.5 Φιλτράρισμα ανά band: `filter_band.py`

Μετά τον ορισμό των ζωνών συχνοτήτων, εφαρμόζεται band-pass φιλτράρισμα ανά κανάλι, ώστε να παραχθούν band-specific σήματα. Στο `filter_band.py` υλοποιείται συνάρτηση που δέχεται:

- το πολυκαναλικό σήμα (`channels × samples`),
- τη συχνότητα δειγματοληψίας  $f_s$ ,
- τα bands ως λίστα ορίων,

και επιστρέφει μία δομή με band-filtered χρονοσειρές.

Listing 7.1: Ενδεικτικό απόσπασμα φιλτραρίσματος ανά band (`filter_band.py`).

```
def filter_with_bands(data, fs, bands, order=4):
    filtered = []
    for (low, high) in bands:
        # band-pass filter per channel
        band_data = bandpass_filter(data, fs, low, high, order=order)
        filtered.append(band_data)
    return filtered
```

## 7.3 Εξαγωγή χαρακτηριστικών

### 7.3.1 RQA: `utils_rqa.py` και `extract_rqa.py`

Η εξαγωγή RQA υλοποιείται σε δύο επίπεδα:

- `utils_rqa.py`: βοηθητικές συναρτήσεις για recurrence matrix και υπολογισμό δεικτών,
- `extract_rqa.py`: orchestration της εξαγωγής χαρακτηριστικών ανά συμμετέχοντα/κανάλι/band.

Στο `utils_rqa.py` ο πυρήνας είναι ο υπολογισμός του πίνακα επαναφοράς:

$$R_{i,j} = \begin{cases} 1, & \|\mathbf{x}_i - \mathbf{x}_j\| \leq \varepsilon \\ 0, & \text{διαφορετικά} \end{cases}$$

όπου τα  $\mathbf{x}_i$  είναι τα time-delay embedded διανύσματα.

Στη συνέχεια υπολογίζονται οι δείκτες (RR, DET, LAM, ENTR). Η λογική στη διπλωματική πρέπει να παρουσιαστεί ως: (α) embedding, (β) recurrence matrix, (γ) γραμμικές δομές και μετρικές.

**Σημείωση υλοποίησης:** στη RQA το κρίσιμο είναι η παραμετροποίηση ( $m, \tau, \varepsilon$ ) και τα thresholds για γραμμές ( $l_{\min}, v_{\min}$ ). Στον κώδικα οι παράμετροι αυτοί είτε είναι σταθερές είτε περνιούνται ως ορίσματα στις συναρτήσεις ώστε να μπορούν να γίνουν πειράματα ευαισθησίας.

### 7.3.2 Bubble Entropy: `bubble_entropy.py`

Πέρα από τους δείκτες RQA, έχει υλοποιηθεί και υπολογισμός *Bubble Entropy*, ως συμπληρωματικό μέτρο πολυπλοκότητας. Η βασική ιδέα είναι ότι η εντροπία υπολογίζεται από τη στατιστική συμπεριφορά προτύπων/σχετικών διατάξεων (ordinal patterns), δίνοντας έναν εναλλακτικό δείκτη μη-γραμμικής πολυπλοκότητας.

Στο `extract_rqa.py` υπάρχει λογική που, για κάθε μονοδιάστατο σήμα (κανάλι ή κανάλι×band), υπολογίζει:

1. RQA feature vector,
2. Bubble Entropy feature vector,

και τα συνενώνει σε ενιαίο feature vector.

Listing 7.2: Ενδεικτικό μοτίβο σύνθεσης RQA + Bubble Entropy (extract\_rqa.py).

```
rqa = compute_rqa_features(signal_1d, ...)
be = bubble_entropy_features(signal_1d, ...)
feats = np.concatenate([rqa, be], axis=0)
```

#### 7.4 Σύντηξη χαρακτηριστικών: fuse\_features.py

Μετά την εξαγωγή χαρακτηριστικών ανά κανάλι και (όπου υπάρχει) ανά band, απαιτείται ένα στάδιο σύντηξης που μετατρέπει μία ιεραρχική δομή (subject → band → channel features) σε ένα ενιαίο διάνυσμα ανά δείγμα.

Το fuse\_features.py υλοποιεί αυτή τη συνένωση με τρόπο που διατηρεί σταθερή σειρά/διάταξη, ώστε:

- το feature vector να έχει σταθερή διάσταση,
- να μην μπερδεύονται bands ή κανάλια μεταξύ τους,
- να είναι δυνατή η αντιστοίχιση με labels (rest/mental, G/B).

Listing 7.3: Ενδεικτική λογική σύντηξης χαρακτηριστικών (fuse\_features.py).

```
def fuse(all_subject_features):
    # Concatenate features across bands/channels into one vector per subj
    X = []
    for subj in all_subject_features:
        X.append(subj.reshape(-1))
    return np.vstack(X)
```

#### 7.5 Εκπαίδευση και αξιολόγηση ταξινομητή: train\_classifier.py

Το train\_classifier.py περιλαμβάνει τη διαδικασία εκπαίδευσης ενός επιβλεπόμενου μοντέλου ταξινόμησης πάνω στον πίνακα χαρακτηριστικών  $X$  και τα labels  $y$ . Σε επίπεδο υλοποίησης, είναι κρίσιμο να τεκμηριώνεται ότι:

- εφαρμόζεται train/test split ή cross-validation,

- οι μετρικές υπολογίζονται με standard ορισμούς (accuracy, precision/recall/F1, confusion matrix),
- αποφεύγεται διαρροή πληροφορίας όταν υπάρχουν πολλαπλά παράθυρα ανά συμμετέχοντα (π.χ. group split).

Listing 7.4: Σκελετός συνάρτησης εκπαίδευσης/αξιολόγησης (train\_classifier.py).

```
def train_model(X, y, ...):  
    # split or cross-validate  
    # fit classifier  
    # evaluate metrics  
    return model, metrics
```

## ΚΕΦΑΛΑΙΟ 8

# ΑΠΟΤΕΛΕΣΜΑΤΑ ΚΑΙ ΣΥΖΗΤΗΣΗ

---

- 8.1 Πειραματικό πρωτόκολλο αξιολόγησης
  - 8.2 Αποτελέσματα LOSO
  - 8.3 Ερμηνεία της μεμονωμένης αποτυχίας
  - 8.4 Συμπληρωματικά αποτελέσματα cross-validation
  - 8.5 Γιατί παρατηρούνται τόσο υψηλά ποσοστά
  - 8.6 Ποιοτική ερμηνεία μέσω recurrence plots
  - 8.7 Συζήτηση και περιορισμοί
- 

Το παρόν κεφάλαιο παρουσιάζει τα αποτελέσματα της προτεινόμενης μεθοδολογίας και συζητά τη σημασία τους με έμφαση στη γενίκευση σε νέο υποκείμενο, στη μεθοδολογική αξιοπιστία και στις ιδιαιτερότητες των EEG δεδομένων. Η παρουσίαση ξεκινά από το πειραματικό πρωτόκολλο αξιολόγησης, το οποίο έχει σχεδιαστεί ώστε να περιορίζει αισιόδοξες εκτιμήσεις απόδοσης και να ευθυγραμμίζεται με ένα ρεαλιστικό σενάριο χρήσης. Στη συνέχεια αναλύονται τα αποτελέσματα του κύριου πειράματος LOSO και παρουσιάζονται συμπληρωματικά αποτελέσματα 5-fold cross-validation ως δεύτερη οπτική σταθερότητας. Ακολουθεί ερμηνεία των πολύ υψηλών ποσοστών ταξινόμησης, με σύνδεση της ποσοτικής εικόνας με τη δυναμική σημασία των RQA χαρακτηριστικών. Τέλος, η ανάλυση συμπληρώνεται από ποιοτική τεκμηρίωση μέσω recurrence plots και κλείνει με συζήτηση περιορισμών και προοπτικών επέκτασης.

## 8.1 Πειραματικό πρωτόκολλο αξιολόγησης

Η αξιολόγηση της προτεινόμενης μεθοδολογίας πραγματοποιήθηκε με subject-wise διαχωρισμό των δεδομένων, έτσι ώστε όλα τα δείγματα ενός συμμετέχοντα να χρησιμοποιούνται αποκλειστικά είτε για εκπαίδευση είτε για έλεγχο. Η επιλογή αυτή είναι κρίσιμη στην ανάλυση EEG, διότι η δια-υποκειμενική μεταβλητότητα είναι συχνά ισχυρή και μπορεί να κυριαρχεί έναντι των διαφορών που οφείλονται στη γνωστική κατάσταση. Σε πρακτικούς όρους, διαφορετικά άτομα μπορεί να έχουν διαφορετικά βασικά επίπεδα ισχύος, διαφορετικές ιδιοσυχνότητες (όπως η θέση του alpha peak), διαφορετικές συνθήκες επαφής ηλεκτροδίων, αλλά και διαφορετική ευαισθησία σε artifacts, ακόμη και όταν τα τμήματα έχουν χαρακτηριστεί ως artifact-free. Αν δεδομένα του ίδιου ατόμου εμφανιστούν σε train και test, το μοντέλο μπορεί να μάθει μοτίβα που λειτουργούν ως «αποτύπωμα υποκειμένου» και να επιτυγχάνει υψηλή ακρίβεια χωρίς να έχει πραγματικά μάθει τη διαφορά ανάμεσα σε ηρεμία και έργο.

Στο κύριο πείραμα εφαρμόστηκε σχήμα leave-one-subject-out. Σε κάθε επανάληψη, ένας συμμετέχοντας χρησιμοποιείται ως test set, ενώ όλοι οι υπόλοιποι σχηματίζουν το training set. Με δεδομένο ότι το EEGMAT παρέχει για κάθε υποκείμενο ένα τμήμα ηρεμίας και ένα τμήμα νοητικής αριθμητικής, το test set κάθε fold περιλαμβάνει δύο δείγματα. Το σημείο αυτό είναι σημαντικό για τη σωστή ερμηνεία των μετρικών: η ακρίβεια ανά fold δεν έχει μεγάλη «ανάλυση», αφού οι δυνατές τιμές είναι 0, 0.5 ή 1.0. Ένα μεμονωμένο λάθος αρκεί για να οδηγήσει σε ακρίβεια 0.5, ενώ δύο σωστές προβλέψεις οδηγούν σε 1.0. Συνεπώς, η αξιολόγηση σε επίπεδο fold λειτουργεί κυρίως ως ένδειξη ύπαρξης ή μη «δύσκολων» υποκειμένων, ενώ η συνολική εικόνα προκύπτει συγκεντρωτικά από το σύνολο των folds.

Παράλληλα, πραγματοποιήθηκε και 5-fold cross-validation ως συμπληρωματικός έλεγχος. Η αξιολόγηση αυτή προσφέρει μια δεύτερη οπτική για τη σταθερότητα του pipeline, καθώς το test set σε κάθε fold είναι μεγαλύτερο και οι μετρικές επηρεάζονται λιγότερο από μεμονωμένα σφάλματα. Ωστόσο, επειδή δεν είναι εγγενώς subject-wise, δεν αντικαθιστά το LOSO ως προς το βασικό ερώτημα γενίκευσης σε νέο άτομο. Για τον λόγο αυτό, το LOSO παραμένει το κύριο πείραμα και το 5-fold CV λειτουργεί συμπληρωματικά.

## 8.2 Αποτελέσματα LOSO

Η συνοπτική εικόνα των αποτελεσμάτων LOSO δείχνει πολύ υψηλή μέση ακρίβεια ίση με 0.9861, με τυπική απόκλιση 0.0822. Στην πλειονότητα των folds η ταξινόμηση είναι τέλεια, ενώ παρατηρείται μία μόνο περίπτωση όπου η ακρίβεια μειώνεται στο 0.5. Η εικόνα αυτή είναι συμβατή με τη δομή του test set: με δύο δείγματα ανά fold, ένα λανθασμένο δείγμα οδηγεί υποχρεωτικά σε 0.5, χωρίς αυτό να συνεπάγεται ότι το μοντέλο αποτυγχάνει συστηματικά.

Η σημαντικότερη ερμηνεία των αποτελεσμάτων προκύπτει από το γεγονός ότι η υψηλή επίδοση εμφανίζεται υπό subject-wise αξιολόγηση. Αυτό υποδηλώνει ότι τα εξαγόμενα χαρακτηριστικά περιέχουν πληροφορία που, τουλάχιστον σε μεγάλο μέρος των συμμετεχόντων, μεταβάλλεται με τρόπο συνεπή ανάμεσα στις δύο συνθήκες. Δηλαδή, το μοντέλο φαίνεται να αξιοποιεί δομικές διαφοροποιήσεις της δυναμικής, οι οποίες δεν εξαρτώνται αποκλειστικά από τα απολύτως υποκειμενο-ειδικά baselines.

Από πρακτική σκοπιά, το εύρημα αυτό είναι ενθαρρυντικό διότι ευθυγραμμίζεται με το σενάριο εφαρμογής: ένα σύστημα που έχει εκπαιδευτεί σε ένα σύνολο ατόμων και καλείται να λειτουργήσει σε νέο χρήστη. Σημειώνεται ότι το LOSO στο EEGMAT είναι αυστηρό όχι μόνο επειδή αλλάζει το άτομο, αλλά και επειδή κάθε test fold είναι μικρό και δεν «συγχωρεί» σφάλματα. Επομένως, το γεγονός ότι το σύστημα αποδίδει τέλεια σχεδόν σε όλα τα folds είναι ένδειξη ότι, για την πλειονότητα των υποκειμένων, η διάκριση resting state (eyes closed) έναντι mental arithmetic εκφράζεται με τρόπο που αποτυπώνεται καθαρά στις δυναμικές μετρικές που υπολογίζονται.

## 8.3 Ερμηνεία της μεμονωμένης αποτυχίας

Η μοναδική περίπτωση μειωμένης ακρίβειας αποτελεί αναμενόμενο φαινόμενο σε βιοϊατρικά δεδομένα και είναι χρήσιμη γιατί δείχνει πού μπορεί να εμφανιστεί το όριο γενίκευσης. Το συγκεκριμένο fold περιλαμβάνει συμμετέχοντα του οποίου η απόκριση στη νοητική αριθμητική φαίνεται να μην αποκλίνει έντονα από την κατάσταση ηρεμίας, τουλάχιστον όπως αυτή αποτυπώνεται από τα χαρακτηριστικά του pipeline.

Μια πρώτη πιθανή εξήγηση είναι η ιδιαιτερότητα του ίδιου του υποκειμένου. Σε

γνωστικά tasks όπως η σειριακή αφαίρεση, άτομα με διαφορετική εμπειρία ή στρατηγική (π.χ. πιο «αυτόματη» εκτέλεση) μπορεί να εμφανίζουν μικρότερη αλλαγή στη δυναμική οργάνωση του EEG σε σχέση με άτομα που καταβάλλουν μεγαλύτερη προσπάθεια. Επίσης, η κόπωση ή μειωμένη εμπλοκή στο έργο μπορεί να μειώσει το διαχωρισμό μεταξύ συνθηκών. Μια δεύτερη εξήγηση αφορά τη μη αντιπροσωπευτικότητα του επιλεγμένου τμήματος mental arithmetic: αν το συγκεκριμένο segment περιέχει μεταβατική περίοδο, διακοπές προσοχής ή μειωμένη ένταση εκτέλεσης, τότε η «υπογραφή έργου» μπορεί να είναι πιο αδύναμη.

Μια τρίτη κατηγορία εξηγήσεων σχετίζεται με την καταγραφή. Ακόμη και όταν τα τμήματα θεωρούνται καθαρά, μικρές αλλαγές στην επαφή ηλεκτροδίων, διαφοροποίηση στην αντίσταση ή ήπια μυϊκή ένταση μπορούν να επηρεάσουν τη δυναμική περιγραφή και να μετατοπίσουν την κατανομή των χαρακτηριστικών του συγκεκριμένου υποκειμένου εκτός της κατανομής που «έμαθε» το μοντέλο. Σε όρους distribution shift, το fold αυτό μπορεί να αποτελεί παράδειγμα υποκειμένου που βρίσκεται πιο μακριά από τον μέσο χώρο χαρακτηριστικών των υπολοίπων.

Η ύπαρξη ενός τέτοιου fold δεν αναιρεί τη συνολική εικόνα, αλλά αναδεικνύει ότι ένα ρεαλιστικό σύστημα πρέπει να περιλαμβάνει μηχανισμούς που αντιμετωπίζουν δύσκολους χρήστες. Πρακτικά, αυτό μπορεί να γίνει είτε με περισσότερα παραδείγματα ανά συνθήκη (π.χ. πολλαπλά παράθυρα αντί για ένα συνολικό segment), είτε με κανονικοποίηση/σταθεροποίηση χαρακτηριστικών, είτε με υβριδικές προσεγγίσεις που συνδυάζουν δυναμικά και πιο κλασικά φασματικά χαρακτηριστικά. Επιπλέον, η αναλυτικότερη διερεύνηση του συγκεκριμένου υποκειμένου (π.χ. σύγκριση των RQA δεικτών του με την κατανομή των υπόλοιπων, ή έλεγχος για διαφοροποιήσεις σε συγκεκριμένα κανάλια) μπορεί να προσφέρει ουσιαστική κατανόηση του πότε και γιατί η γενίκευση αποδυναμώνεται.

## 8.4 Συμπληρωματικά αποτελέσματα cross-validation

Στο 5-fold cross-validation παρατηρήθηκαν επίσης πολύ υψηλές επιδόσεις, με μέση ακρίβεια 0.9867 και μικρότερη τυπική απόκλιση. Η μείωση της διακύμανσης σε σχέση με το LOSO είναι αναμενόμενη, καθώς κάθε fold περιλαμβάνει περισσότερα δείγματα στο test set και η επίδραση ενός μεμονωμένου σφάλματος εξομαλύνεται. Με άλλα λόγια, η στατιστική «ανάλυση» της ακρίβειας είναι εδώ μεγαλύτερη και

τα αποτελέσματα εμφανίζονται πιο σταθερά.

Τα αποτελέσματα αυτά λειτουργούν ως ένδειξη ότι το pipeline είναι γενικά συνεπές και δεν εμφανίζει ακραίες διακυμάνσεις όταν αλλάζει ο διαχωρισμός των δεδομένων. Ωστόσο, η ερμηνεία πρέπει να γίνεται προσεκτικά: σε προβλήματα EEG, οι τυπικές διαδικασίες cross-validation μπορεί να είναι λιγότερο αυστηρές ως προς τη γενίκευση σε νέο υποκείμενο, ιδιαίτερα αν ο διαχωρισμός δεν επιβάλλεται σε επίπεδο ατόμου. Για τον λόγο αυτό, το 5-fold CV αντιμετωπίζεται ως συμπληρωματική εικόνα σταθερότητας και όχι ως κύρια απόδειξη cross-subject γενίκευσης.

## 8.5 Γιατί παρατηρούνται τόσο υψηλά ποσοστά

Η υψηλή απόδοση που παρατηρείται δεν είναι απαραίτητα αντιφατική με το περιορισμένο μέγεθος του δείγματος, εφόσον ληφθεί υπόψη η φύση του προβλήματος και το είδος των χαρακτηριστικών. Η διάκριση μεταξύ ηρεμίας με κλειστά μάτια και νοητικής αριθμητικής είναι ένα σχετικά ισχυρό σενάριο, επειδή οι δύο καταστάσεις διαφέρουν ουσιαστικά ως προς το συνολικό λειτουργικό πλαίσιο του εγκεφάλου. Η ηρεμία (eyes closed) συχνά χαρακτηρίζεται από πιο σταθερή, ρυθμική δραστηριότητα, ενώ η νοητική αριθμητική εισάγει αυξημένη εμπλοκή προσοχής και εκτελεστικών λειτουργιών, κάτι που μπορεί να οδηγήσει σε πιο ασταθή και σύνθετη δυναμική.

Σε αυτό το πλαίσιο, τα RQA χαρακτηριστικά είναι κατάλληλα επειδή στοχεύουν ακριβώς σε δομικές ιδιότητες της δυναμικής και όχι μόνο σε μέσες τιμές ισχύος. Για παράδειγμα, αυξημένη determinism μπορεί να σημαίνει ότι η δυναμική ακολουθεί πιο προβλέψιμα μοτίβα (κάτι που είναι πιθανότερο σε πιο σταθερές καταστάσεις), ενώ μειωμένη laminarity μπορεί να αντανακλά λιγότερη «παραμονή» του συστήματος σε συγκεκριμένες περιοχές του χώρου καταστάσεων. Αντίστοιχα, αυξημένη entropy των γραμμών στο recurrence plot μπορεί να αποτυπώνει μεγαλύτερη ποικιλία δυναμικών μοτίβων, κάτι που είναι συμβατό με μια γνωστικά απαιτητική κατάσταση.

Ένας επιπλέον πρακτικός παράγοντας είναι η χρήση τμημάτων που έχουν επιλεγεί ως artifact-free. Όταν το σήμα είναι σχετικά καθαρό, η αναλογία ωφέλιμης πληροφορίας προς θόρυβο αυξάνεται, με αποτέλεσμα οι δυναμικές διαφορές να αποτυπώνονται πιο καθαρά. Σε πιο ρεαλιστικές συνθήκες, όπου υπάρχουν περισ-

σότερα artifacts ή μεταβατικές περιόδους, η ίδια μεθοδολογία ενδέχεται να εμφανίσει μειωμένη απόδοση, γεγονός που υπογραμμίζει τη σημασία της αξιολόγησης και της επέκτασης σε πιο ετερογενή δεδομένα.

Τέλος, πρέπει να ληφθεί υπόψη ότι το μικρό test set ανά fold στο LOSO δημιουργεί μια ιδιόμορφη εικόνα: οι περισσότερες επαναλήψεις οδηγούν σε τέλεια ακρίβεια, ενώ μια αποτυχία εμφανίζεται ως 0.5. Συνεπώς, η πολύ υψηλή μέση τιμή είναι εύλογη, αλλά η πλήρης στατιστική τεκμηρίωση θα ενισχυόταν σημαντικά αν υπήρχαν περισσότερα ανεξάρτητα δείγματα ανά υποκείμενο (π.χ. πολλαπλά windows ανά συνθήκη) ή περισσότερα άτομα.

## 8.6 Ποιοτική ερμηνεία μέσω recurrence plots

Η ποιοτική διαφοροποίηση μεταξύ των δύο συνθηκών γίνεται εμφανής και μέσω των recurrence plots, τα οποία παρέχουν μια πιο άμεση οπτική εικόνα της δυναμικής οργάνωσης. Στην κατάσταση ηρεμίας, τα recurrence plots τείνουν να εμφανίζουν πιο πυκνά και δομημένα μοτίβα, όπως συνεχείς ή εκτενείς διαγώνιες δομές και συστάδες, οι οποίες αντιστοιχούν σε επαναληψιμότητα και πιο οργανωμένη εξέλιξη του σήματος. Στη νοητική αριθμητική, αντίθετα, η δομή συχνά γίνεται πιο αραιή και λιγότερο κανονική, κάτι που συνάδει με αυξημένη δυναμική πολυπλοκότητα και μεγαλύτερη ποικιλία καταστάσεων στο χρόνο.

Η σύνδεση αυτής της εικόνας με τις ποσοτικές μετρικές είναι άμεση: πιο πυκνό plot συνδέεται με υψηλότερο recurrence rate, πιο έντονες διαγώνιες γραμμές με υψηλότερο determinism, ενώ μεταβολές στη μορφή και στο πλήθος των κατακόρυφων δομών αντανακλώνται στη laminarity. Αντίστοιχα, όταν η δυναμική εμφανίζει μεγαλύτερη ποικιλία οργανωτικών μοτίβων, η εντροπία των δομών στο recurrence plot μπορεί να αυξηθεί.

Παρότι τα recurrence plots βοηθούν στην ερμηνεία, δεν πρέπει να αντιμετωπίζονται ως αυτόνομη απόδειξη. Αποτελούν οπτική τεκμηρίωση που υποστηρίζει την ποσοτική εικόνα, αλλά εξαρτώνται από επιλογές παραμετροποίησης και από το επιλεγμένο τμήμα σήματος. Για τον λόγο αυτό, η κύρια τεκμηρίωση παραμένει η subject-wise αξιολόγηση και οι αντίστοιχες μετρικές απόδοσης, ενώ τα plots λειτουργούν συμπληρωματικά.

## 8.7 Συζήτηση και περιορισμοί

Συνολικά, τα αποτελέσματα δείχνουν ότι το προτεινόμενο pipeline, βασισμένο σε μη-γραμμική ανάλυση μέσω RQA, μπορεί να διαχωρίσει με πολύ υψηλή ακρίβεια την κατάσταση ηρεμίας από τη νοητική αριθμητική, ακόμη και σε πλαίσιο γενίκευσης ανά υποκείμενο. Αυτό ενισχύει το βασικό συμπέρασμα ότι η δυναμική δομή του EEG περιέχει χρήσιμη πληροφορία για την αναγνώριση γνωστικής κατάστασης, η οποία δεν περιορίζεται σε απλές μεταβολές ισχύος.

Παρά τα ενθαρρυντικά ευρήματα, υπάρχουν περιορισμοί που πρέπει να ληφθούν υπόψη. Ο αριθμός συμμετεχόντων είναι περιορισμένος, κάτι που επηρεάζει τη στατιστική ισχύ και δυσκολεύει την εξαγωγή πολύ γενικών συμπερασμάτων για διαφορετικούς πληθυσμούς και διαφορετικά πρωτόκολλα. Επιπλέον, το εξεταζόμενο πρόβλημα είναι δυαδικό και σχετικά καθαρό, γεγονός που ευνοεί υψηλές επιδόσεις σε σχέση με πιο λεπτές κατηγοριοποιήσεις, όπως πολλαπλά επίπεδα workload ή διαφορετικοί τύποι εργασιών.

Τέλος, η RQA εξαρτάται από επιλογές παραμέτρων όπως το embedding, το threshold και το μήκος τμήματος. Παρότι οι επιλογές εφαρμόστηκαν με συνεπή τρόπο, δεν είναι βέβαιο ότι είναι βέλτιστες για κάθε dataset ή κάθε ρύθμιση. Μια συστηματική ανάλυση ευαισθησίας ή μια διαδικασία αυτοματοποίησης επιλογής παραμέτρων θα ενίσχυε την εγκυρότητα και θα μείωνε τον κίνδυνο οι επιδόσεις να είναι μερικώς αποτέλεσμα συγκεκριμένων ρυθμίσεων.

Παρά τους περιορισμούς, η προσέγγιση παραμένει ερμηνεύσιμη και αναπαραγώγιμη, και παρέχει μια σαφή βάση για μελλοντικές επεκτάσεις σε μεγαλύτερα datasets, σε πολυ-κατηγορικά σενάρια workload και σε υβριδικές αναπαραστάσεις που συνδυάζουν RQA με συμπληρωματικές δυναμικές ή φασματικές πληροφορίες.

# ΚΕΦΑΛΑΙΟ 9

## ΣΥΜΠΕΡΑΣΜΑΤΑ ΚΑΙ ΜΕΛΛΟΝΤΙΚΗ ΕΡΓΑΣΙΑ

---

### 9.1 Συμπεράσματα

### 9.2 Περιορισμοί

### 9.3 Μελλοντική εργασία

---

### 9.1 Συμπεράσματα

Η παρούσα διπλωματική εργασία ανέπτυξε, υλοποίησε και αξιολόγησε ένα πλήρες υπολογιστικό πλαίσιο για την ανάλυση ΗΕΓ σημάτων σε συνθήκες αυξημένου γνωστικού φορτίου, με στόχο τη βιοϊατρικά ερμηνεύσιμη και μεθοδολογικά έγκυρη αυτόματη διάκριση μεταξύ κατάστασης ηρεμίας (*resting state*, κλειστά μάτια) και νοητικής αριθμητικής (*mental arithmetic*). Η μελέτη βασίστηκε στο δημόσια διαθέσιμο σύνολο δεδομένων EEGMAT, το οποίο περιλαμβάνει καταγραφές ανά συμμετέχοντα στις δύο παραπάνω συνθήκες και επιτρέπει αξιολόγηση σε σενάριο γενίκευσης σε επίπεδο υποκειμένου, κάτι που είναι ιδιαίτερα απαιτητικό σε EEG.

Κεντρικός άξονας της εργασίας ήταν να εξεταστεί κατά πόσο χαρακτηριστικά που αποτυπώνουν τη δυναμική δομή του EEG, και όχι μόνο μια «στατική» περίληψη ισχύος ή φάσματος, μπορούν να οδηγήσουν σε αξιόπιστη ταξινόμηση γνωστικών καταστάσεων. Για τον σκοπό αυτό υιοθετήθηκε ως βασικός μηχανισμός εξαγωγής χαρακτηριστικών η *Recurrence Quantification Analysis (RQA)*. Η RQA αντιμετωπίζει το EEG ως έκφραση ενός σύνθετου δυναμικού συστήματος και ποσοτικοποιεί το πώς οργανώνονται οι επαναληπτικές δομές της δυναμικής στο χρόνο, μέσω μετρικών

όπως ο *Recurrence Rate (RR)*, ο *Determinism (DET)*, η *Laminarity (LAM)* και η *Entropy (ENTR)*.

Στο προτεινόμενο pipeline, τα RQA χαρακτηριστικά εξήχθησαν ανά κανάλι και, όπου εφαρμόστηκε, και ανά φιλτραρισμένη εκδοχή του σήματος (σε κλασικές και/ή δεδομενοκεντρικές ζώνες συχνοτήτων). Στη συνέχεια, οι επιμέρους περιγραφές συνδυάστηκαν σε ενιαία αναπαράσταση μέσω *feature fusion*. Έτσι, το σύστημα δεν βασίζεται σε μία μόνο «οπτική γωνία», αλλά σε σύνθεση πληροφοριών που καλύπτει χωρική, συχνοτική και δυναμική διάσταση του EEG.

Σε επίπεδο αξιολόγησης, χρησιμοποιήθηκε πρωτόκολλο *leave-one-subject-out (LOSO)*, ώστε η εκτίμηση απόδοσης να αντανακλά το πρακτικό σενάριο: εκπαίδευση σε μια ομάδα ατόμων και πρόβλεψη σε ένα νέο, μη-παρατηρηθέν άτομο. Η επιλογή αυτή είναι κρίσιμη, γιατί στο EEG η δια-υποκειμενική μεταβλητότητα είναι ισχυρή και οι λιγότερο αυστηρές στρατηγικές αξιολόγησης μπορούν εύκολα να οδηγήσουν σε υπερεκτίμηση της επίδοσης λόγω έμμεσου leakage.

Τα αποτελέσματα έδειξαν ότι το προτεινόμενο pipeline επιτυγχάνει **πολύ υψηλή απόδοση** στη διάκριση μεταξύ ηρεμίας και νοητικής αριθμητικής, με μέση ακρίβεια **0.986** υπό LOSO αξιολόγηση. Η τιμή αυτή υποστηρίζει τη βασική υπόθεση της εργασίας: τα RQA χαρακτηριστικά μπορούν να αποτυπώσουν ουσιαστικές διαφορές στην οργάνωση της δυναμικής που σχετίζονται με το γνωστικό φορτίο και να παραμείνουν διακριτικά ακόμη και όταν αλλάζει το άτομο.

Παράλληλα, η ανάλυση σε επίπεδο folds έδειξε ότι δεν είναι όλα τα test υποκείμενα ισοδύναμα ως προς τη δυσκολία ταξινόμησης. Σε ορισμένα folds η επίδοση ήταν χαμηλότερη, κάτι που είναι σημαντικό εύρημα από μόνο του: δείχνει ότι η γενίκευση δεν «κλειδώνει» αυτόματα ακόμη και όταν ο μέσος όρος είναι πολύ υψηλός. Ένα απλό παράδειγμα για το πώς μπορεί να προκύψει αυτό είναι το εξής: αν ένας συμμετέχων έχει υψηλότερο baseline alpha στο resting state ή παρουσιάζει πιο συχνά μικρο-artifacts (π.χ. ήπια EMG ένταση), τότε το μοντέλο μπορεί να βλέπει μια κατανομή χαρακτηριστικών που αποκλίνει από τα άτομα εκπαίδευσης. Σε ένα LOSO fold, αυτό μεταφράζεται σε περισσότερα λάθη σε συγκεκριμένες περιπτώσεις, όχι επειδή η μέθοδος «αποτυγχάνει συνολικά», αλλά επειδή το cross-subject shift είναι πραγματικό και εμφανίζεται σε συγκεκριμένα άτομα πιο έντονα. Με άλλα λόγια, ο μέσος όρος συνοφίξει την εικόνα, αλλά τα «δύσκολα» άτομα είναι αυτά που δείχνουν πού χρειάζεται βελτίωση για πραγματικό deployment.

Συνολικά, η εργασία τεκμηριώνει ότι η μη-γραμμική περιγραφή μέσω RQA μπο-

ρεί να είναι αποτελεσματική και σχετικά ερμηνεύσιμη για το συγκεκριμένο πρόβλημα, ότι η συνδυαστική αξιοποίηση πολλαπλών περιγραφών μέσω feature fusion μπορεί να ενισχύει τη σταθερότητα της ταξινόμησης, και ότι η subject-wise αξιολόγηση αποτελεί προϋπόθεση ώστε η reported επίδοση να συνδέεται με πραγματική δυνατότητα εφαρμογής. Επιπλέον, η υλοποίηση με σαφή καταγραφή παραμέτρων, αποθήκευση ενδιάμεσων artifacts και αναπαραγωγίμη ροή επεξεργασίας ενισχύει τη συνολική αναπαραγωγιμότητα και επιτρέπει στο pipeline να επεκταθεί με ελεγχόμενο τρόπο.

## 9.2 Περιορισμοί

Παρά τα ενθαρρυντικά αποτελέσματα, υπάρχουν περιορισμοί που επηρεάζουν την ερμηνεία και τη γενίκευση των συμπερασμάτων.

Πρώτον, το διαθέσιμο πλήθος συμμετεχόντων είναι σχετικά περιορισμένο. Στο πλαίσιο LOSO, το test set σε κάθε fold αντιστοιχεί σε ένα μόνο άτομο και περιέχει μικρό αριθμό παραδειγμάτων, όπως προκύπτει από τη δομή του EEGMAT. Αυτό οδηγεί σε αυξημένη διακύμανση της ακρίβειας ανά fold και σε «ακραίες» τιμές σε ορισμένες περιπτώσεις. Δεν αναιρεί την υψηλή μέση επίδοση, αλλά σημαίνει ότι η εκτίμηση είναι ευαίσθητη σε λίγες δύσκολες περιπτώσεις και ότι η εικόνα της γενίκευσης χρειάζεται επιβεβαίωση σε μεγαλύτερα/διαφορετικά datasets.

Δεύτερον, η εργασία εξετάζει ένα σχετικά «καθαρό» πρωτόκολλο δυαδικής διάκρισης (rest vs mental arithmetic). Σε τέτοια σενάρια οι διαφορές είναι συχνά πιο έντονες από ό,τι σε πιο λεπτές διακρίσεις (π.χ. πολλαπλά επίπεδα workload ή διαφορετικοί τύποι γνωστικών εργασιών). Συνεπώς, η πολύ υψηλή επίδοση στο EEGMAT δεν σημαίνει αυτόματα ότι θα επιτευχθεί αντίστοιχη απόδοση σε πιο σύνθετα ή πιο οικολογικά έγκυρα περιβάλλοντα.

Τρίτον, η RQA εξαρτάται από κρίσιμες παραμέτρους, όπως η διάσταση embedding  $m$ , η καθυστέρηση  $\tau$  και το threshold  $\epsilon$ , οι οποίες επηρεάζουν άμεσα τη recurrence δομή και τις μετρικές που προκύπτουν. Αν και στο pipeline η επιλογή παραμέτρων έγινε με συνεπή τρόπο, παραμένει πιθανό οι τιμές αυτές να μην είναι βέλτιστες για όλα τα δεδομένα, όλα τα κανάλια ή άλλα πρωτόκολλα. Άρα, για γενίκευση σε νέα δεδομένα απαιτείται είτε συστηματική ανάλυση ευαισθησίας είτε μια πιο αυτοματοποιημένη επιλογή παραμέτρων, ειδικά όταν ο στόχος είναι

deployment-aligned LOSO.

Τέταρτον, παρότι η προσέγγιση είναι πιο ερμηνεύσιμη από end-to-end deep μοντέλα, η εργασία δεν ολοκλήρωσε πλήρως μια λεπτομερή χαρτογράφηση του ποια κανάλια, περιοχές ή συχνοτικές συνιστώσες συμβάλλουν συστηματικά στην ταξινόμηση. Μια τέτοια ανάλυση είναι κρίσιμη για ισχυρότερα βιοϊατρικά συμπεράσματα και για να μεταφερθεί το αποτέλεσμα από «το μοντέλο δουλεύει» σε «γιατί δουλεύει και τι σημαίνει νευροφυσιολογικά».

Τέλος, η επιλογή να μην χρησιμοποιηθεί βαθιά μάθηση (*deep learning*) συνδέεται άμεσα με το μέγεθος και τη δομή των διαθέσιμων δεδομένων. Τα deep μοντέλα συνήθως απαιτούν πολύ μεγαλύτερο όγκο ανεξάρτητων παραδειγμάτων ώστε να μάθουν σταθερές, γενικεύσιμες αναπαραστάσεις χωρίς να υπερπροσαρμόζονται σε subject-specific μοτίβα. Στο EEGMAT, ο αριθμός υποκειμένων είναι μικρός και τα δεδομένα είναι ιδιαίτερα συσχετισμένα χρονικά, άρα η «τεχνητή» αύξηση δειγμάτων μέσω segmentation δεν ισοδυναμεί με πραγματική αύξηση πληροφορίας. Σε αυτή τη ρύθμιση, ένα end-to-end deep μοντέλο θα είχε αυξημένο κίνδυνο να μάθει fingerprints του συμμετέχοντα ή ιδιαιτερότητες της καταγραφής, ειδικά αν δεν εφαρμοστούν πολύ αυστηρά subject-wise splits, nested επιλογές υπερπαραμέτρων και επιπλέον τεχνικές regularization. Για τον λόγο αυτό, η εργασία προτίμησε ένα pipeline με χειροποίητα/δομημένα χαρακτηριστικά (RQA) και κλασικούς ταξινομητές, ώστε (α) να περιοριστεί ο κίνδυνος overfitting, (β) να ενισχυθεί η ερμηνευσιμότητα και (γ) να διατηρηθεί η μεθοδολογική καθαρότητα υπό LOSO.

### 9.3 Μελλοντική εργασία

Με βάση τα παραπάνω, προκύπτουν ρεαλιστικές κατευθύνσεις για επέκταση και εμπάθυνση της εργασίας.

Μια άμεση επέκταση είναι η εφαρμογή του pipeline σε μεγαλύτερα και πιο ετερογενή σύνολα δεδομένων, καθώς και σε δεδομένα από διαφορετικά εργαστήρια/εξοπλισμό. Αυτό θα επιτρέψει να εξεταστεί η ανθεκτικότητα της μεθόδου σε αλλαγές αριθμού καναλιών, διαφορετικές πρακτικές προεπεξεργασίας και πιο ετερογενείς πληθυσμούς. Αν η επίδοση παραμείνει σταθερή σε δια-εργαστηριακά δεδομένα, θα ενισχυθεί σημαντικά η εξωτερική εγκυρότητα και η βιοϊατρική αξιοπιστία των συμπερασμάτων.

Επιπλέον, αντί για μία συνολική αναπαράσταση ανά συνθήκη, μπορεί να εξεταστεί συστηματικά η τμηματοποίηση σε παράθυρα με αυστηρό subject-wise διαχωρισμό και αποφυγή leakage. Αυτό θα επιτρέψει μελέτη ενδο-συνθηκικών μεταβολών (π.χ. κόπωση, προσαρμογή, αλλαγή στρατηγικής), εκτίμηση της σταθερότητας των RQA χαρακτηριστικών στο χρόνο, και ανάπτυξη μοντέλων που ανιχνεύουν μεταβάσεις (*state transitions*) αντί για στατικές ετικέτες. Ένα πρακτικό παράδειγμα είναι η διάκριση «έναρξη mental arithmetic» έναντι «σταθεροποιημένης εκτέλεσης», όπου το workload πιθανόν να εμφανίζει μεταβατικό στάδιο που δεν αποτυπώνεται από ένα μόνο summary.

Ένα ακόμη σημαντικό βήμα είναι η συστηματική διερεύνηση ευαισθησίας ως προς τις παραμέτρους ( $m, \tau, \epsilon$ ) και η αυτοματοποίηση της επιλογής τους. Αυτό μπορεί να γίνει με nested subject-wise διαδικασίες για model/parameter selection, με στρατηγικές σταθερού recurrence rate (π.χ. percentile-based thresholding) ή με βελτιστοποίηση που εξισορροπεί υπολογιστικό κόστος και γενίκευση. Στόχος είναι η παραμετροποίηση να μετατραπεί από εμπειρική επιλογή σε αναπαραγώγιμο στάδιο του pipeline.

Η ερμηνευσιμότητα μπορεί να ενισχυθεί με ανάλυση σημαντικότητας χαρακτηριστικών και ablation μελέτες, καθώς και με συστηματική διερεύνηση καναλιών/περιοχών που συνεισφέρουν περισσότερο. Για παράδειγμα, αν προκύψει ότι συγκεκριμένες fronto-parietal περιοχές παρουσιάζουν σταθερά διαφορετική δυναμική οργάνωση μεταξύ rest και task, τότε η συμβολή μεταφέρεται από «υψηλή ακρίβεια» σε πιο νευροφυσιολογικά θεμελιωμένο συμπέρασμα.

Παρότι η παρούσα εργασία επέλεξε να μην χρησιμοποιήσει deep learning λόγω των περιορισμών δεδομένων, μελλοντικά μπορεί να διερευνηθεί η χρήση υβριδικών προσεγγίσεων όταν υπάρχουν περισσότερα δεδομένα ή όταν αξιοποιηθούν τεχνικές που μειώνουν τον κίνδυνο overfitting. Ενδεικτικά, μπορούν να εξεταστούν (α) self-supervised προεκπαίδευση σε μεγάλα ακατέργαστα EEG datasets και fine-tuning στο EEGMAT, (β) domain adaptation τεχνικές για cross-subject shift, και (γ) μοντέλα που ενσωματώνουν ρητά subject-invariant constraints. Εναλλακτικά, ακόμη και χωρίς πλήρες end-to-end deep learning, μπορεί να αξιοποιηθεί deep feature extraction πάνω σε αναπαραστάσεις όπως time-frequency maps, με αυστηρό LOSO και nested επιλογές.

Τέλος, ιδιαίτερο ενδιαφέρον παρουσιάζει η επέκταση σε πιο ρεαλιστικά σενάρια όπου η γνωστική κατάσταση δεν είναι δυαδική. Πιθανές επεκτάσεις είναι η διάκριση

πολλαπλών επιπέδων workload (π.χ. easy/medium/hard), η αναγνώριση διαφορετικών τύπων γνωστικών εργασιών και η εφαρμογή σε πιο «φυσικά» περιβάλλοντα (π.χ. HCI, προσομοιωτές). Σε τέτοια σενάρια, η ανθεκτικότητα σε artifacts, η διαχείριση distribution shift και η μεθοδολογικά αυστηρή αξιολόγηση αποκτούν ακόμη μεγαλύτερη σημασία.

Συμπερασματικά, η παρούσα διπλωματική δείχνει ότι η μη-γραμμική ανάλυση μέσω RQA αποτελεί ισχυρό εργαλείο για την αποτύπωση διαφορών γνωστικής κατάστασης σε EEG, ενώ ταυτόχρονα αναδεικνύει σαφείς κατευθύνσεις για περαιτέρω βελτίωση σε επίπεδο γενίκευσης, παραμετροποίησης, ερμηνευσιμότητας και εφαρμογής σε πιο σύνθετα βιοϊατρικά σενάρια. Η συνολική συνεισφορά δεν περιορίζεται στην υψηλή επίδοση, αλλά στην τεκμηρίωση ενός αναπαραγώγιμου και μεθοδολογικά ορθού πλαισίου, το οποίο μπορεί να λειτουργήσει ως βάση για μελλοντική έρευνα και μεταφορά σε εφαρμογές παρακολούθησης γνωστικού φόρτου.

## ΒΙΒΛΙΟΓΡΑΦΙΑ

---

- [1] Y. Furman, R. Itzhack, G. Nini, R. Puzis, and S. Marks, “Short-time fourier transform and embedding method for recurrence quantification analysis of EEG time series,” *The European Physical Journal Special Topics*, vol. 232, no. 1, pp. 135–149, 2022.
- [2] Z. Zheng and L. Weng, “Automated recognition of mental cognitive workload through nonlinear eeg analysis,” *Web Intelligence*, vol. 23, no. 1, pp. 56–72, 2025. [Online]. Available: <https://doi.org/10.3233/WEB-240141>
- [3] I. Albuquerque, T. Zhang, C. A. Sánchez, A. Jahanian, A. J. Karran, T. Zhao *et al.*, “Estimating distribution shifts for predicting cross-subject generalization in electroencephalography-based mental workload assessment,” *Frontiers in Artificial Intelligence*, vol. 5, p. 992732, 2022.
- [4] G. Brookshire, J. Kasper, N. M. Blauch, Y. C. Wu, R. Glatt, D. A. Merrill, S. Gerrol, K. J. Yoder, C. Quirk, and C. Lucero, “Data leakage in deep learning studies of translational EEG,” *Frontiers in Neuroscience*, vol. 18, p. 1373515, 2024.
- [5] F. Del Pup, A. Zanola, L. F. Tshimanga, A. Bertoldo, L. Finos, and M. Atzori, “The role of data partitioning on the performance of EEG-based deep learning models in supervised cross-subject analysis: A preliminary study,” *Computers in Biology and Medicine*, vol. 196, no. Part A, p. 110608, 2025.
- [6] K. S. Ang, Z. N. Chin, C. W. Wang *et al.*, “EEG-based discrimination of different cognitive workload levels from mental arithmetic,” in *Proceedings of the Annual International Conference of the IEEE Engineering in Medicine and Biology Society (EMBC)*, 2018, pp. 1984–1987.
- [7] A. H. Harrison, M. D. Noseworthy, J. P. Reilly, W. Guan, and J. F. Connolly, “Eeg and fmri agree: Mental arithmetic is the easiest form of imagery to detect,”

- Consciousness and Cognition*, vol. 48, pp. 104–116, 2017. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S1053810016303762>
- [8] T. Inouye, K. Shinosaki, A. Iyama, and Y. M. Matsumoto, “Localization of activated areas and directional eeg patterns during mental arithmetic.” *Electroencephalography and clinical neurophysiology*, vol. 86 4, pp. 224–30, 1993. [Online]. Available: <https://api.semanticscholar.org/CorpusID:4548650>
- [9] T. Harmony, T. Fernández, J. Silva, J. Bosch, P. Valdés, A. Fernández-Bouzas, L. Galán, E. Aubert, and D. Rodríguez, “Do specific eeg frequencies indicate different processes during mental calculation?” *Neuroscience Letters*, vol. 266, no. 1, pp. 25–28, 1999. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S030439409900244X>
- [10] X. Yu, J. Zhang, D. Xie, J. Wang, and C. Zhang, “Relationship between scalp potential and autonomic nervous activity during a mental arithmetic task,” *Autonomic neuroscience : basic & clinical*, vol. 146, pp. 81–6, 02 2009.
- [11] Z. Garakh, Y. Zaytseva, A. Kapranova, O. Fiala, J. Horacek, A. Shmukler, I. Y. Gurovich, and V. B. Strelets, “Eeg correlates of a mental arithmetic task in patients with first episode schizophrenia and schizoaffective disorder,” *Clinical Neurophysiology*, vol. 126, no. 11, pp. 2090–2098, 2015. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S1388245715000607>
- [12] T. Azizi, “Impact of mental arithmetic task on the electrical activity of the human brain,” *Neuroscience Informatics*, vol. 4, no. 2, p. 100162, 2024. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S2772528624000074>
- [13] A. Duru and M. Assem, “Investigating neural efficiency of elite karate athletes during a mental arithmetic task using eeg,” *Cognitive Neurodynamics*, vol. 12, 02 2018.
- [14] K. Kim, D. NGUYEN, M. Choi, and B. Lee, “Eeg microstate features according to performance on a mental arithmetic task,” *Scientific Reports*, vol. 11, 01 2021.
- [15] M. Malali, Y. Sarbaz, S. Zolfaghari, and A. Khodayarlou, “The influence of mental calculations on brain regions and heart rates,” *Scientific Reports*, vol. 14, 08 2024.

- [16] C. Liu, C. Zhang, L. Sun, K. Liu, H. Liu, W. Zhu, and C. Jiang, "Detection of pilot's mental workload using a wireless eeg headset in airfield traffic pattern tasks," *Entropy*, vol. 25, no. 7, 2023. [Online]. Available: <https://www.mdpi.com/1099-4300/25/7/1035>
- [17] S. Talebi, J. Waczak, B. A. Fernando, A. Sridhar, and D. J. Lary, "Data-driven eeg band discovery with decision trees," *Sensors*, vol. 22, no. 8, 2022. [Online]. Available: <https://www.mdpi.com/1424-8220/22/8/3048>
- [18] A. Varshney, S. K. Ghosh, S. Padhy, R. K. Tripathy, and U. R. Acharya, "Automated classification of mental arithmetic tasks using recurrent neural network and entropy features obtained from multi-channel eeg signals," *Electronics*, vol. 10, no. 9, 2021. [Online]. Available: <https://www.mdpi.com/2079-9292/10/9/1079>
- [19] A. Khosla, P. Khandnor, and T. Chand, "Eeg-based automatic multi-class classification of epileptic seizure types using recurrence plots," *Expert Systems*, vol. 39, 12 2021.
- [20] S. Kongwudhikunakorn, W. Ponwitayarat, S. Kiatthaveephong, W. Polpakdee, T. Yagi, V. Senanarong, P. Ittichaiwong, and T. Wilaiprasitporn, "Eegmenet: End-to-end multitask neural network for brain-based mental workload classification," *IEEE Internet of Things Journal*, vol. PP, pp. 1–1, 10 2025.
- [21] M. Aslam, F. Rajbdad, S. Azmat, K. Perveen, M. Naraghi-Pour, and J. Xu, "Electroencephalograph (eeg) based classification of mental arithmetic using explainable machine learning," *Biocybernetics and Biomedical Engineering*, vol. 45, no. 2, pp. 154–169, 2025. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0208521625000075>
- [22] N. Baygin, E. Aydemir, P. D. Barua, M. Baygin, S. Dogan, T. Tuncer, R.-S. Tan, and U. Rajendra Acharya, "Automated mental arithmetic performance detection using quantum pattern- and triangle pooling techniques with eeg signals," *Expert Systems with Applications*, vol. 227, p. 120306, 2023. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S0957417423008084>
- [23] S. Karmakar, S. Das, C. Koley, and T. Pal, "Detection of cognitive workload using optimized number of eeg features," 12 2024, pp. 1–7.

- [24] P. Rithwik, V. Benzy, and A. Vinod, “High accuracy decoding of motor imagery directions from eeg-based brain computer interface using filter bank spatially regularised common spatial pattern method,” *Biomedical Signal Processing and Control*, vol. 72, p. 103241, 2022. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S1746809421008387>
- [25] V. S. Kardam, S. Taran, and A. Pandey, “Motor imagery tasks based electroencephalogram signals classification using data-driven features,” *Neuroscience Informatics*, vol. 3, no. 2, p. 100128, 2023. [Online]. Available: <https://www.sciencedirect.com/science/article/pii/S2772528623000134>
- [26] S. Aggarwal and N. Chugh, “Review of machine learning techniques for eeg based brain computer interface,” *Archives of Computational Methods in Engineering*, vol. 29, 01 2022.
- [27] P. Samal and M. F. Hashmi, “Role of machine learning and deep learning techniques in eeg-based bci emotion recognition system: a review,” *Artificial Intelligence Review*, 02 2024.
- [28] P. Bomatter, J. Paillard, P. Garces, J. F. Hipp, and D. Engemann, “Machine learning of brain-specific biomarkers from eeg,” *bioRxiv*, 2023.
- [29] I. Zyma, S. Tukaev, I. Seleznov, K. Kiyono, A. Popov, M. Chernykh, and O. Shpenkov, “Electroencephalograms during mental arithmetic task performance,” *Data*, vol. 4, no. 1, p. 14, 2019.

# ΠΑΡΑΡΤΗΜΑ Α

## ΛΕΠΤΟΜΕΡΕΙΕΣ ΥΛΟΠΟΙΗΣΗΣ ΚΑΙ ΠΑΡΑΜΕΤΡΟΠΟΙΗΣΗΣ PIPELINE

- 
- A.1 Παράμετροι προεπεξεργασίας
  - A.2 Παράμετροι ανακάλυψης ζωνών συχνότητας
  - A.3 Παράμετροι Recurrence Quantification Analysis
  - A.4 Δομή διανύσματος χαρακτηριστικών
  - A.5 Αποθηκευμένα artifacts και αναπαραγωγιμότητα
- 

Το παρόν παράρτημα συγκεντρώνει αναλυτικές πληροφορίες σχετικά με τις παραμέτρους και τις επιλογές υλοποίησης του προτεινόμενου υπολογιστικού pipeline. Η παρουσίασή τους εκτός του κύριου σώματος του κειμένου επιτρέπει την πληρέστερη τεκμηρίωση της μεθοδολογίας, χωρίς να επιβαρύνει την κύρια ροή της ανάλυσης, και διευκολύνει την αναπαραγωγιμότητα των πειραμάτων.

### A.1 Παράμετροι προεπεξεργασίας

Η προεπεξεργασία εφαρμόζεται με στόχο τη δημιουργία συγκρίσιμων και σταθερών εισόδων για τα επόμενα στάδια του pipeline. Οι βασικές παράμετροι συνοφίζονται ως εξής:

- Συχνότητα δειγματοληψίας:  $f_s = 500$  Hz (όπως ορίζεται στο EEGMAT).
- Κανονικοποίηση: προαιρετική κανονικοποίηση τύπου z-score ανά κανάλι.
- Τμηματοποίηση: όπου εφαρμόζεται, χρησιμοποιούνται παράθυρα σταθερού μήκους, με ή χωρίς επικάλυψη, πάντα με subject-wise διαχωρισμό.

Η κανονικοποίηση ανά κανάλι συμβάλλει στη σταθερότερη επιλογή του κατωφλίου  $\varepsilon$  στη RQA, καθώς περιορίζει τις διαφορές κλίμακας μεταξύ συμμετεχόντων.

## A.2 Παράμετροι ανακάλυψης ζωνών συχνότητων

Η ανακάλυψη ζωνών συχνότητων υλοποιείται με δεδομενοκεντρική προσέγγιση. Αντί για αυστηρά προκαθορισμένα όρια, τα bands προκύπτουν από την ανάλυση του φασματικού περιεχομένου των σημάτων.

Η έξοδος του σταδίου αυτού αποθηκεύεται σε αρχείο `bands.json`, το οποίο περιέχει ζεύγη ορίων ( $f_{low}$ ,  $f_{high}$ ) και επαναχρησιμοποιείται στο φιλτράρισμα, διασφαλίζοντας συνέπεια μεταξύ διαφορετικών εκτελέσεων του pipeline.

## A.3 Παράμετροι Recurrence Quantification Analysis

Η RQA βασίζεται στην ανακατασκευή του χώρου φάσεων μέσω χρονικής ενσωμάτωσης. Οι βασικές παράμετροι που χρησιμοποιούνται συνοψίζονται παρακάτω:

- Διάσταση ενσωμάτωσης:  $m$ .
- Χρονική καθυστέρηση:  $\tau$ .
- Κατώφλι επαναφοράς:  $\varepsilon$ , οριζόμενο ως συνάρτηση της διασποράς του σήματος.
- Ελάχιστο μήκος διαγώνιων γραμμών:  $l_{min}$ .
- Ελάχιστο μήκος κατακόρυφων γραμμών:  $v_{min}$ .
- Μετρική απόστασης: Ευκλείδεια νόρμα.

Οι τιμές των παραμέτρων είτε ορίζονται σταθερά είτε περνιούνται ως ορίσματα στις συναρτήσεις, ώστε να είναι δυνατή η ανάλυση ευαισθησίας και η συστηματική διερεύνηση εναλλακτικών ρυθμίσεων.

## A.4 Δομή διανύσματος χαρακτηριστικών

Για κάθε δείγμα, τα χαρακτηριστικά οργανώνονται ιεραρχικά ως εξής:

subject → band → channel → (RQA + Bubble Entropy)

Η τελική σύντηξη πραγματοποιείται με σταθερή σειρά bands και καναλιών, ώστε το προκύπτον διάνυσμα χαρακτηριστικών να έχει σταθερή διάσταση και σαφή αντιστοίχιση με τα labels των πειραματικών συνθηκών.

## A.5 Αποθηκευμένα artifacts και αναπαραγωγιμότητα

Για τη διασφάλιση της αναπαραγωγιμότητας, το pipeline αποθηκεύει ενδιάμεσα και τελικά artifacts, όπως:

- `bands.json`: ορισμοί ζωνών συχνοτήτων,
- `X_rqa_be.npz`: πίνακας χαρακτηριστικών,
- `pipeline_report.txt`: συνοπτική αναφορά εκτέλεσης.

Η αποθήκευση των artifacts επιτρέπει την επανάληψη πειραμάτων, την επαλήθευση ενδιάμεσων αποτελεσμάτων και τη συστηματική σύγκριση διαφορετικών παραμετροποιήσεων χωρίς επανυπολογισμό όλων των σταδίων.

## ΔΗΜΟΣΙΕΥΣΕΙΣ ΣΥΓΓΡΑΦΕΑ

---

- D. I. Kiromitis, C. V. Bellos, K. A. Stefanou, G. S. Stergios, T. Katsantas, S. Kontogiannis, *Performance Evaluation of Classification Algorithms to Detect Bee Swarming Events Using Sound*, *Signals*, vol. 3, no. 4, pp. 807–822, 2022. doi:10.3390/signals3040048.
- D. I. Kiromitis, C. V. Bellos, K. A. Stefanou, G. S. Stergios, T. Katsantas, S. Kontogiannis, *Bee Sound Detector: An Easy-to-Install, Low-Power, Low-Cost Beehive Conditions Monitoring System*, *Electronics*, vol. 11, no. 19, art. 3152, 2022. doi:10.3390/electronics11193152.

# ΣΥΝΤΟΜΟ ΒΙΟΓΡΑΦΙΚΟ

---

Ο Κυρομίτης Δημήτριος του Ιωάννη, είναι μεταπτυχιακός φοιτητής στο πρόγραμμα Μηχανική Δεδομένων και Υπολογιστικών Συστημάτων του τμήματος Μηχανικών Η/Υ και Πληροφορικής της Πολυτεχνικής Σχολής του Πανεπιστημίου Ιωαννίνων. Αποφοίτησε από το Τμήμα Μαθηματικών του Πανεπιστημίου Ιωαννίνων το 2022.

Τα ερευνητικά του ενδιαφέροντα εστιάζουν στην επεξεργασία και ανάλυση σημάτων, στη μηχανική μάθηση και στην IoT εφαρμογές στον τομέα της Γεωργίας. Στο πλαίσιο της παρούσας διπλωματικής εργασίας ασχολήθηκε με εξαγωγή μη γραμμικών χαρακτηριστικών (RQA), φασματικές αναπαραστάσεις και αυστηρή αξιολόγηση γενίκευσης ανά υποκείμενο. Έχει εμπειρία σε Python και εργαλεία ανάλυσης δεδομένων (NumPy, SciPy, scikit-learn), σε αναπαραγωγίμα πειραματικά pipelines καθώς και στις IoT τεχνολογίες.