

# AI / ML στην εκπαίδευση και στις μαθησιακές δυσκολίες

Αδάμ Στυλιανή

Επιβλέπων Καθηγητής: Αριστείδης Βραχάτης

Εργαστήριο BIHELAB, ΤΠΛΗ, ΙΠ



# Εισαγωγή

- Οι μαθησιακές δυσκολίες (π.χ. ADHD, dyslexia) επηρεάζουν μεγάλο ποσοστό μαθητών παγκοσμίως
- Η διάγνωση βασίζεται συχνά σε κλινικές παρατηρήσεις και ερωτηματολόγια, τα οποία μπορεί να είναι υποκειμενικά
- Η τεχνητή νοημοσύνη επιτρέπει την ανάλυση μεγάλων και σύνθετων δεδομένων
- Τα μοντέλα Machine Learning μπορούν να εντοπίσουν μοτίβα συμπεριφοράς και γνωστικής λειτουργίας που δεν είναι εύκολα ορατά



# Τι χρειαζόμαστε

- ▶ Αντικειμενικά διαγνωστικά εργαλεία
- ▶ Δεδομένα από βιοσήματα, συμπεριφορά και γνωστικά τεστ μπορούν να αναλυθούν με machine learning
- ▶ Χρήση multimodal data για να βελτιωθεί η κατανόηση των μαθησιακών δυσκολιών
- ▶ Έρευνα που να στοχεύει στη δημιουργία υποστηρικτικών εργαλείων για ειδικούς και εκπαιδευτικούς

Ανάπτυξη Μοντέλων και Εφαρμογών  
Διάγνωσης ΔΕΠΥ με χρήση πολυτροπικών  
δεδομένων και αλγορίθμους μηχανικής  
μάθησης





# Η ΔΕΠΥ & η Πρόκληση της Διάγνωσης

- Συχνή νευροαναπτυξιακή διαταραχή (5–7% παιδιά, 2–4% ενήλικες)
- Συμπτώματα: απροσεξία, υπερκινητικότητα, παρορμητικότητα
- Προκαλεί σημαντικές δυσκολίες σε σχολείο, εργασία, κοινωνική ζωή
- Η διάγνωση βασίζεται σε υποκειμενικά εργαλεία (συνεντεύξεις, ερωτηματολόγια)
- Ετερογένεια συμπτωμάτων & συννοσηρότητες (άγχος, κατάθλιψη) περιπλέκουν τη διάγνωση
- Ανάγκη: Αντικειμενικοί βιοδείκτες & τεχνολογικά εργαλεία υποστήριξης
- Στόχος εργασίας: Αξιοποίηση πολυτροπικών δεδομένων με Μηχανική Μάθηση για ανάπτυξη διαγνωστικών μοντέλων



# Βιβλιογραφική Ανασκόπηση - Επιστημονικό Πλαίσιο

- Αυξανόμενο ενδιαφέρον για αξιοποίηση Τεχνητής Νοημοσύνης στη μελέτη της ΔΕΠΥ
- Δεδομένα που χρησιμοποιούνται:
  - Νευροαπεικόνιση (fMRI, EEG)
  - Φυσιολογικά σήματα (HRV, EDA)
  - Νευροψυχολογικά τεστ (π.χ. CPT-II, Stroop)
  - Συμπεριφορικοί δείκτες (actigraphy, οφθαλμοκίνηση)
- Στόχος: Αντικειμενικότερη διάγνωση και κατανόηση νευροβιολογικών μηχανισμών
- Προκλήσεις: Ετερογένεια πληθυσμών, μικρά δείγματα, διαφορετικά πρωτόκολλα

# Βιβλιογραφική Ανασκόπηση – Ενδεικτικές Ερευνητικές Προσεγγίσεις (I)

## ➤ **Tang et al. (2022)**

- Dataset: fMRI από ενήλικες με/χωρίς ΔΕΠΥ
- Μέθοδος: Autoencoders για εξαγωγή χαρακτηριστικών + ταξινόμηση
- Αποτέλεσμα: Ακρίβεια ~99%

## ➤ **Andrikopoulos et al. (2024)**

- Dataset: Πολυτροπικά φυσιολογικά σήματα (EDA, HRV, θερμοκρασία δέρματος)
- Μέθοδος: Random Forest & Gradient Boosting σε επιλεγμένα features
- Αποτέλεσμα: Ακρίβεια ~82%

## ➤ **Alsharif et al. (2024)**

- Dataset: EEG καταγραφές παιδιών με ΔΕΠΥ
- Μέθοδος: Υβριδικό CNN + LSTM για ταξινόμηση
- Αποτέλεσμα: Ακρίβεια >95%

Tang, Y., Sun, J., Wang, C., Zhong, Y., Jiang, A., Liu, G., & Liu, X. (2022). ADHD classification using auto-encoding neural network and binary hypothesis testing. *Artificial Intelligence in Medicine*, 123, 102209.

Andrikopoulos, D., Vassiliou, G., Fatouros, P., Tsimpas, C., Pehlivanidis, A., & Papageorgiou, C. (2024). Machine learning-enabled detection of attention deficit/hyperactivity disorder with multimodal physiological data: a case-control study. *BMC psychiatry*, 24(1), 547

Alsharif, N., Al-Adhaileh, M. H., & Al-Yaari, M. (2024). Diagnosis of attention deficit hyperactivity disorder: A deep learning approach. *AIMS Mathematics*, 9(5), 10580-10608.

# Βιβλιογραφική Ανασκόπηση – Ενδεικτικές Ερευνητικές Προσεγγίσεις (II)

## ► **Wiebe et al. (2024)**

- Dataset: VR περιβάλλον με EEG, actigraphy, οφθαλμοκίνηση
- Μέθοδος: Multimodal fusion με ML classifiers
- Αποτέλεσμα: Ακρίβεια ~81%

## ► **Das & Khanna (2021)**

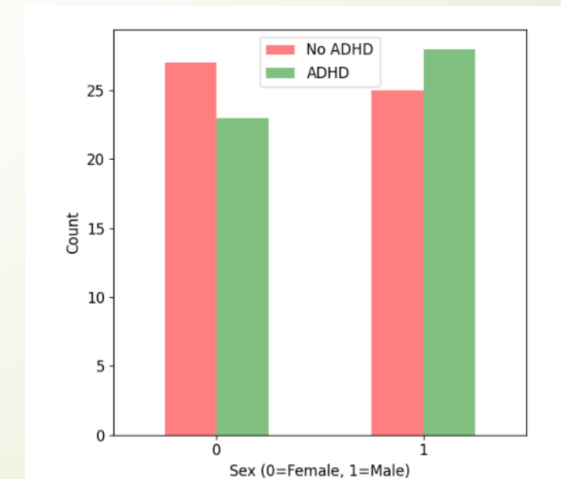


- Dataset: Pupillometry (διάμετρος κόρης) σε ενήλικες με ΔΕΠΥ
- Μέθοδος: SVM σε χαρακτηριστικά pupil dilation
- Αποτέλεσμα: Ακρίβεια ~87%



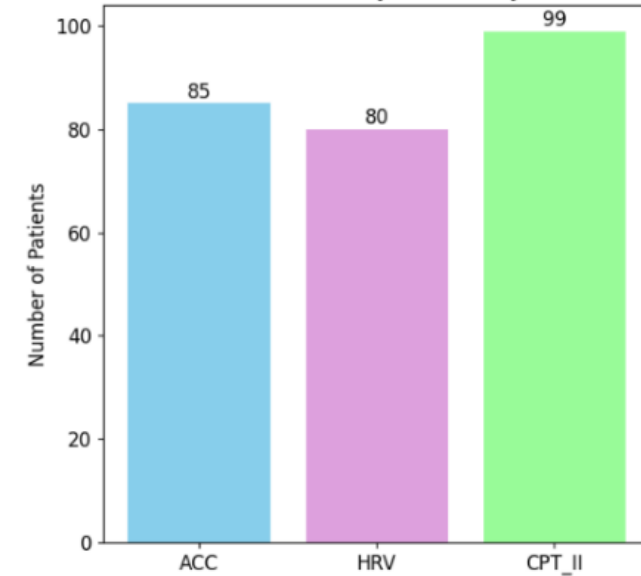

## ► **Fasmer et al. (2020)**



- Dataset: Actigraphy σε ενήλικες για μέτρηση κιρκάδιου ρυθμού
- Μέθοδος: Ανάλυση κιρκάδιων δεικτών με ML μοντέλα
- Αποτέλεσμα: Υποσχόμενη διάκριση ΔΕΠΥ από υγιείς μάρτυρες


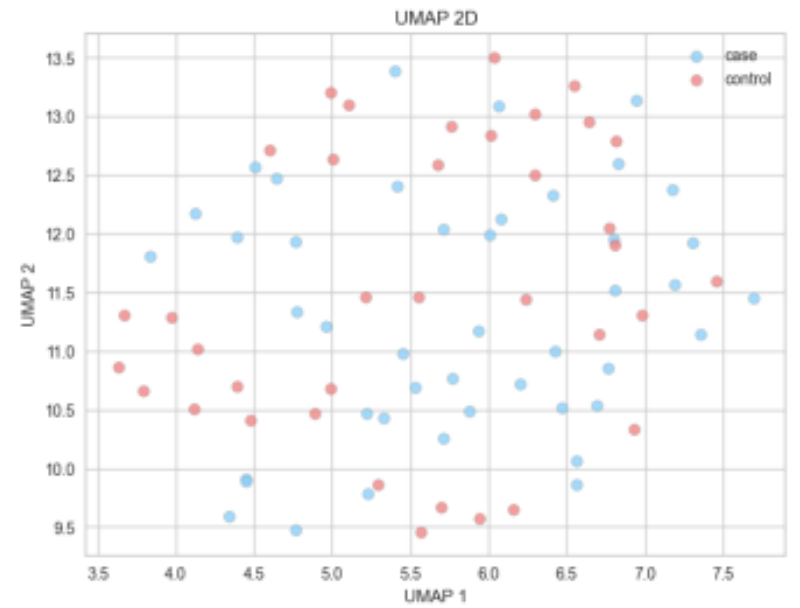

# Περιγραφή Δεδομένων - Dataset

- Δημόσιο dataset **HYPERAKTIV**  
(ενήλικες με/χωρίς ΔΕΠΥ)
- Συνολικό δείγμα: 103 συμμετέχοντες  
(51 ADHD, 52 controls)
- Modalities: Actigraphy, HRV, CPT-II,  
δημογραφικά, κλινικές κλίμακες
- Πλεονέκτημα: πολυτροπικό και μη  
επεμβατικό











# Προεπεξεργασία Δεδομένων

- Καθαρισμός, κανονικοποίηση και ενοποίηση πολυτροπικών δεδομένων
- Αντιμετώπιση ελλιπών τιμών
- Επιλογή χαρακτηριστικών (Feature Selection) σε 2 σενάρια:
  - Actigraphy + CPT-II
  - Actigraphy + HRV
- Στόχος: μείωση διάστασης, βελτίωση γενίκευσης

# Σύγκριση Feature Selection (RFE)

## Σενάριο 1 – Actigraphy + CPT-II

- ▶ Συμμετέχοντες: 80
- ▶ Αρχικά χαρακτηριστικά: 1562
- ▶ Feature Selection: RFECV με 20-fold CV
- ▶ Βέλτιστος αριθμός: 15 χαρακτηριστικά
- ▶ Οφέλη: μείωση υπερπροσαρμογής, βελτίωση ερμηνευσιμότητας

## Σενάριο 2 – Actigraphy + HRV

- ▶ Συμμετέχοντες: 50 (25 ADHD, 25 controls)
- ▶ Χαρακτηριστικά: actigraphy + HRV
- ▶ Feature Selection: stratified k-fold CV
- ▶ Βέλτιστος αριθμός: 5 χαρακτηριστικά
- ▶ Οφέλη: ανάδειξη πολυτροπικών πιθανών βιοδεικτών

# Classification

- Στόχος: διάκριση ADHD από Controls
- Δύο σενάρια:
  - Actigraphy + CPT-II
  - Actigraphy + HRV
- Αλγόριθμοι του 1<sup>ου</sup> σεναρίου: Decision Tree, Random Forest, Gradient Boosting, XGBoost, LightGBM, AdaBoost, CatBoost, Extra Trees και RUSBoost
- Αλγόριθμοι του 2ου σεναρίου: Bernoulli Naive Bayes, Gaussian Naive Bayes, Gradient Boosting, Logistic Regression, Random Forest, Support Vector Machine (SVM) και Stochastic Gradient Descent (SGD)
- Αξιολόγηση: stratified k-fold cross-validation
- Μετρικές: Accuracy, Precision, Recall, F1-score, ROC-AUC



# Clustering

- Σενάριο: Actigraphy + HRV
- Αλγόριθμος: K-means clustering
- Κανονικοποίηση με StandardScaler
- Δείκτες αξιολόγησης: Silhouette, Calinski–Harabasz, Elbow method
- Στόχος: ανίχνευση πιθανών υποομάδων ανεξάρτητα από labels

# Αποτελέσματα

Classification –  
Actigraphy + CPT-II  
(Full Dataset)

Algorithm	Accuracy	F1	AUC	Precision	Recall
Decision Tree	0.53	0.52	0.51	0.49	0.60
Random Forest	<b>0.70</b>	<b>0.70</b>	<b>0.67</b>	<b>0.67</b>	<b>0.77</b>
Gradient Boosting	0.55	0.55	0.55	0.55	0.62
XGBoost	0.51	0.55	0.50	0.53	0.65
LightGBM	0.62	0.62	0.63	0.55	0.75
AdaBoost	0.53	0.49	0.51	0.47	0.52
CatBoost	0.67	0.69	0.66	0.66	<b>0.77</b>
Extra Trees	0.59	0.59	0.56	0.57	0.67
RUSBoost	0.50	0.49	0.51	0.50	0.55

Classification –  
Actigraphy + CPT-II  
(FS)

Algorithm	Accuracy	F1	AUC	Precision	Recall
Decision Tree	0.79	0.77	0.77	0.79	0.80
Random Forest	<b>0.90</b>	0.84	<b>0.87</b>	0.84	0.87
Gradient Boosting	0.83	0.78	0.82	0.82	0.77
XGBoost	0.88	<b>0.86</b>	<b>0.87</b>	<b>0.88</b>	0.87
LightGBM	0.79	0.79	0.83	0.78	0.85
AdaBoost	0.62	0.57	0.60	0.59	0.60
CatBoost	0.85	0.84	0.85	0.83	<b>0.90</b>
Extra Trees	0.83	0.83	0.82	0.84	0.87
RUSBoost	0.75	0.69	0.73	0.69	0.75

20-fold stratified cross-validation

# Αποτελέσματα – Test Test

Classification –  
Actigraphy + CPT-II  
(Full Dataset)

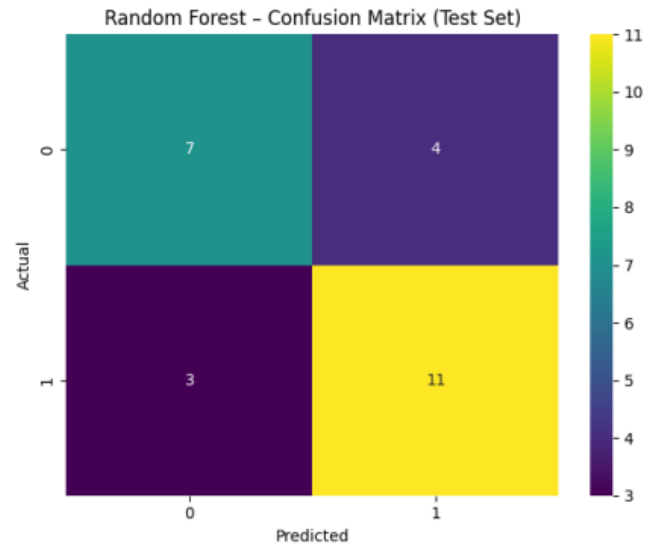
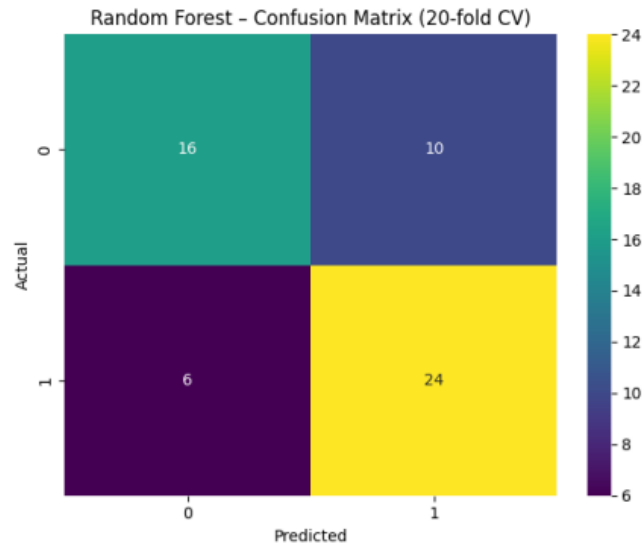
Algorithm	Accuracy	F1	AUC	Precision	Recall
Decision Tree	0.68	0.71	0.67	0.71	0.71
Random Forest	0.72	0.75	0.77	0.73	0.78
Gradient Boosting	0.72	0.75	0.81	0.73	0.78
XGBoost	0.84	0.83	0.93	1.00	0.71
LightGBM	0.64	0.64	0.72	0.72	0.57
AdaBoost	0.68	0.69	0.73	0.75	0.64
CatBoost	0.72	0.77	0.86	0.70	0.85
Extra Trees	0.60	0.68	0.78	0.61	0.78
RUSBoost	0.80	0.78	0.85	1.00	0.64

Classification –  
Actigraphy + CPT-II  
(FS)

Algorithm	Accuracy	F1	AUC	Precision	Recall
Decision Tree	0.76	0.78	0.75	0.78	0.78
Random Forest	0.72	0.74	0.82	0.76	0.71
Gradient Boosting	0.80	0.81	0.86	0.84	0.78
XGBoost	0.80	0.80	0.85	0.90	0.71
LightGBM	0.76	0.76	0.85	0.83	0.71
AdaBoost	0.72	0.74	0.81	0.86	0.71
CatBoost	0.76	0.76	0.85	0.83	0.71
Extra Trees	0.60	0.58	0.70	0.70	0.50
RUSBoost	0.76	0.75	0.87	0.90	0.64

Training Set (70%) και Test Set (30%)

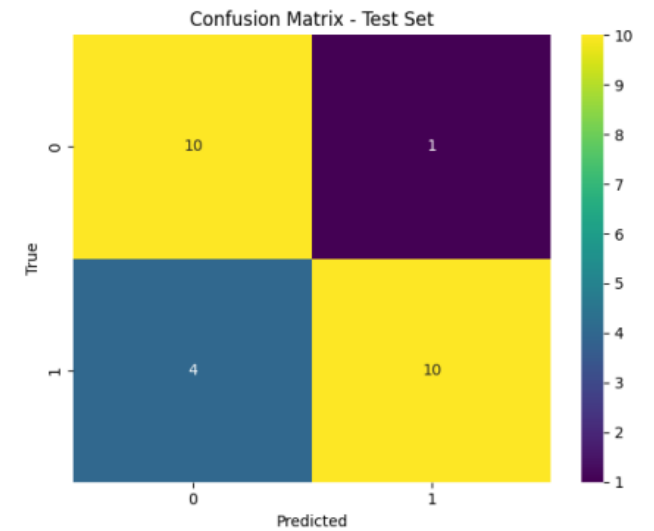

# Καλύτεροι Αλγόριθμοι




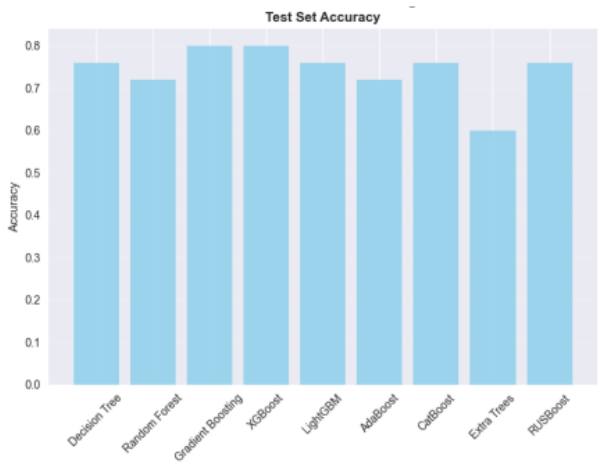


Random Forest



XGBoost





# Αξιολόγηση του βέλτιστου αλγορίθμου σε διακριτά υποσύνολα

Dataset	Accuracy	F1	AUC	Precision	Recall
Cross-Validation	0.85	0.79	0.83	0.83	0.80
Test Set	0.72	0.74	0.82	0.76	0.71


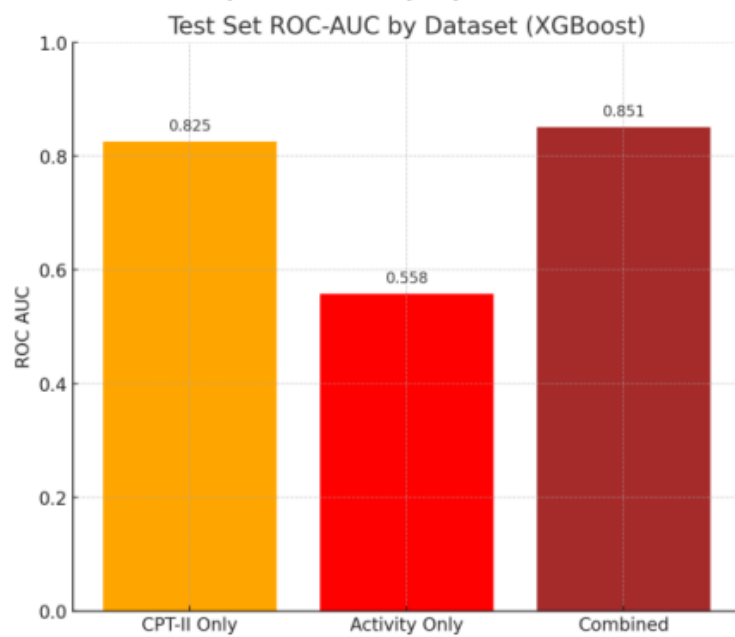


CPT-II subset

Dataset	Accuracy	F1	AUC	Precision	Recall
Cross-Validation	0.66	0.59	0.66	0.63	0.62
Test Set	0.44	0.41	0.55	0.50	0.35

Activity subset


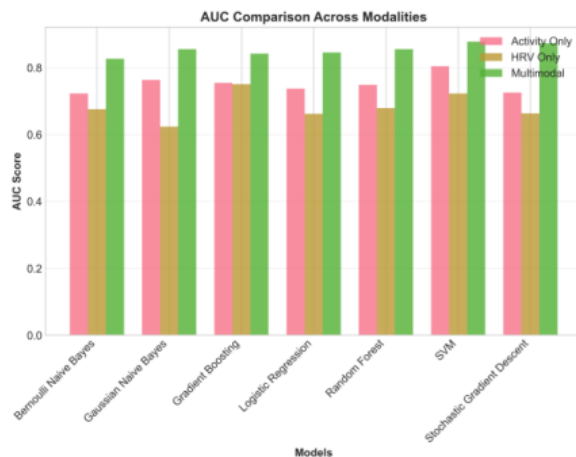
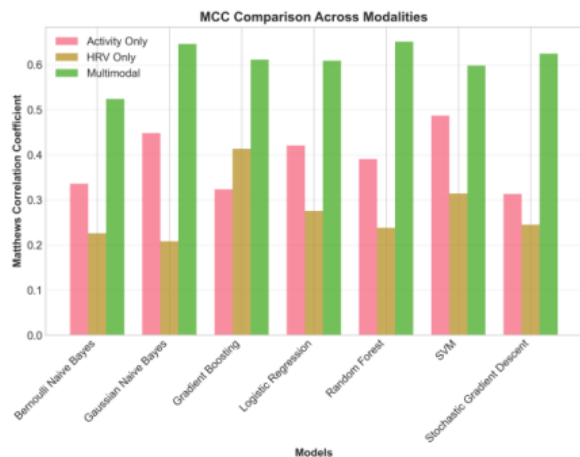
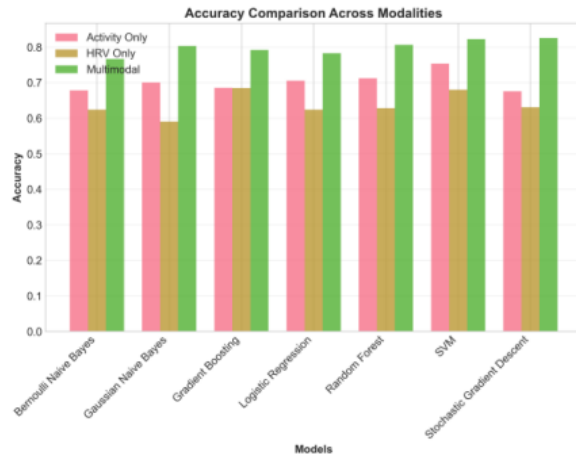
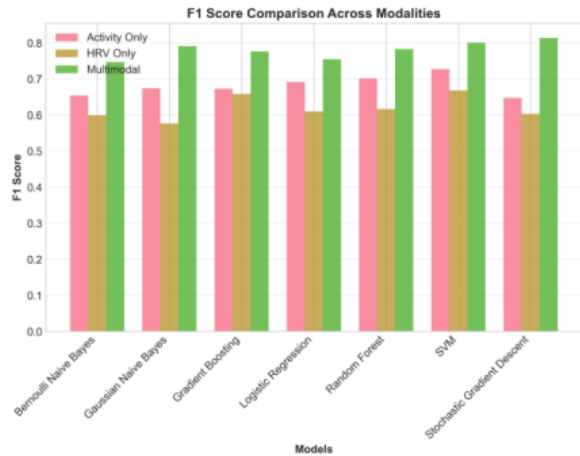
Dataset	Accuracy	F1	AUC	Precision	Recall
Cross-Validation	0.88	0.86	0.87	0.88	0.87
Test Set	0.80	0.80	0.85	0.90	0.71

Combined subset




# Αποτελέσματα Actigraphy + HRV

Model	Activity Only						HRV Only						Multimodal					
	Acc	F1	Prec	Rec	MCC	AUC	Acc	F1	Prec	Rec	MCC	AUC	Acc	F1	Prec	Rec	MCC	AUC
Bernoulli Naive Bayes	0.67	0.65	0.68	0.65	0.33	0.72	0.62	0.59	0.64	0.61	0.22	0.67	0.76	0.74	0.79	0.75	0.52	0.82
Gaussian Naive Bayes	0.70	0.67	0.67	0.72	0.44	0.76	0.59	0.57	0.60	0.60	0.20	0.62	0.80	0.79	0.82	0.78	0.64	0.85
Gradient Boosting	0.68	0.67	0.69	0.69	0.32	0.75	0.68	0.65	0.71	0.70	0.41	0.75	0.79	0.77	0.80	0.79	0.61	0.84
Logistic Regression	0.70	0.69	0.68	0.70	0.42	0.73	0.62	0.61	0.59	0.65	0.27	0.66	0.78	0.75	0.77	0.76	0.60	0.84
Random Forest	0.71	0.70	0.72	0.71	0.39	0.74	0.62	0.61	0.61	0.63	0.23	0.67	0.80	0.78	0.82	0.81	0.65	0.85
SVM	0.75	0.72	0.73	0.73	0.48	0.80	0.68	0.66	0.65	0.66	0.31	0.72	0.82	0.80	0.79	0.79	0.59	0.87
Stochastic Gradient Descent	0.67	0.64	0.68	0.67	0.31	0.72	0.63	0.60	0.65	0.63	0.24	0.66	0.82	0.81	0.81	0.80	0.62	0.87


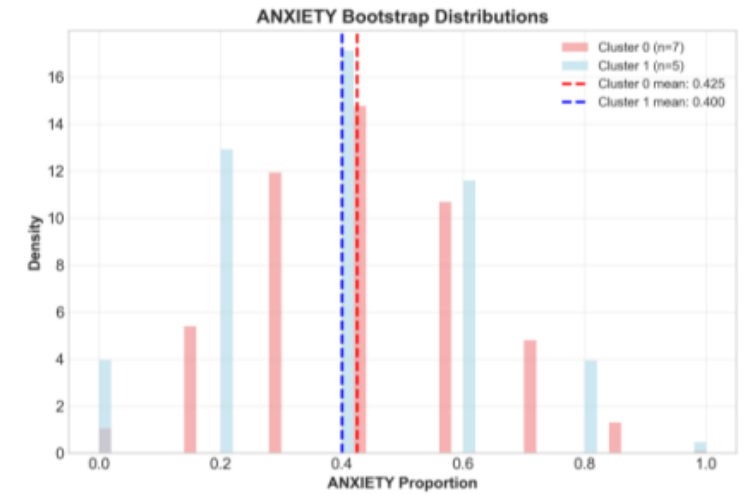
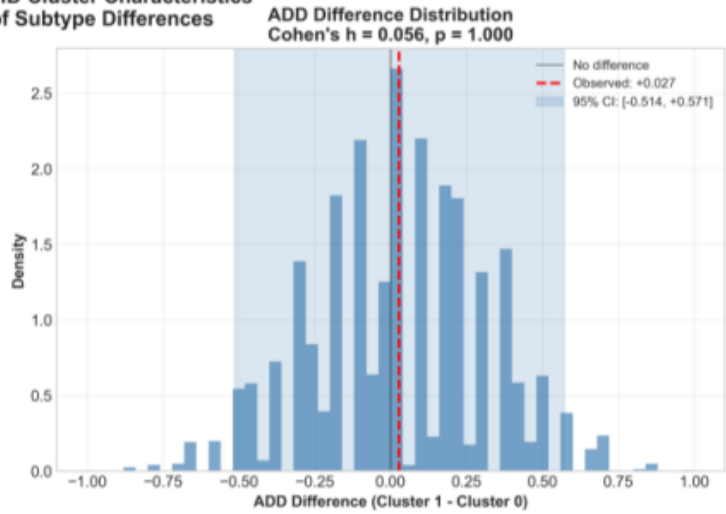
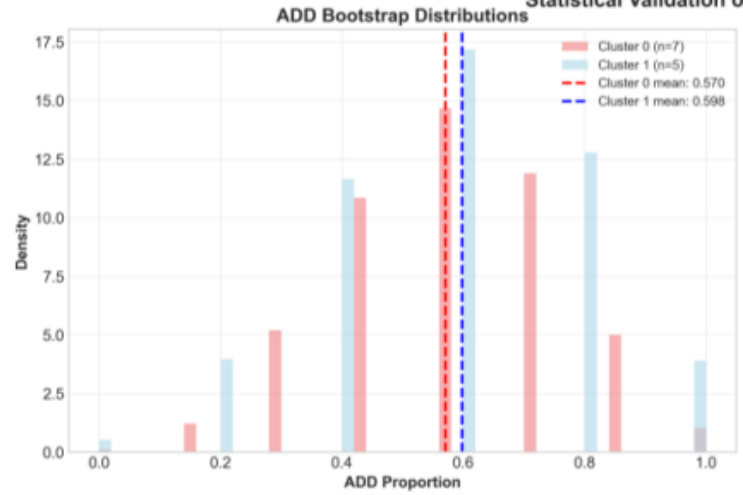




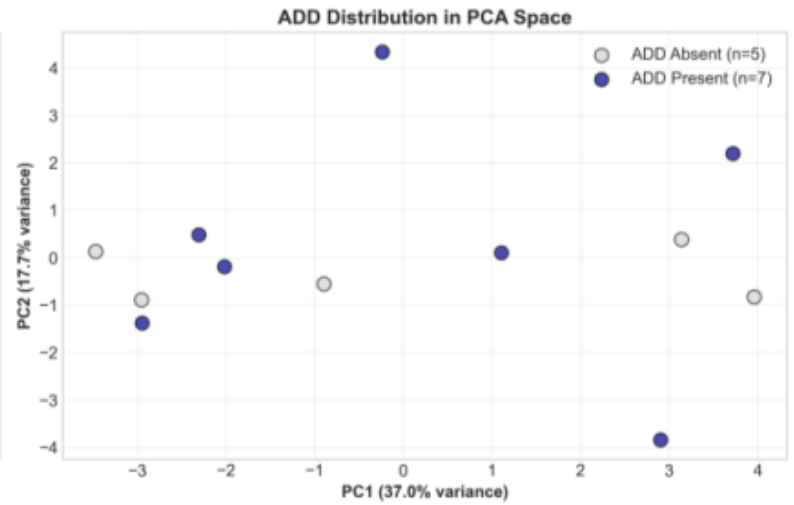

# Αποτελέσματα Clustering Actigraphy + HRV



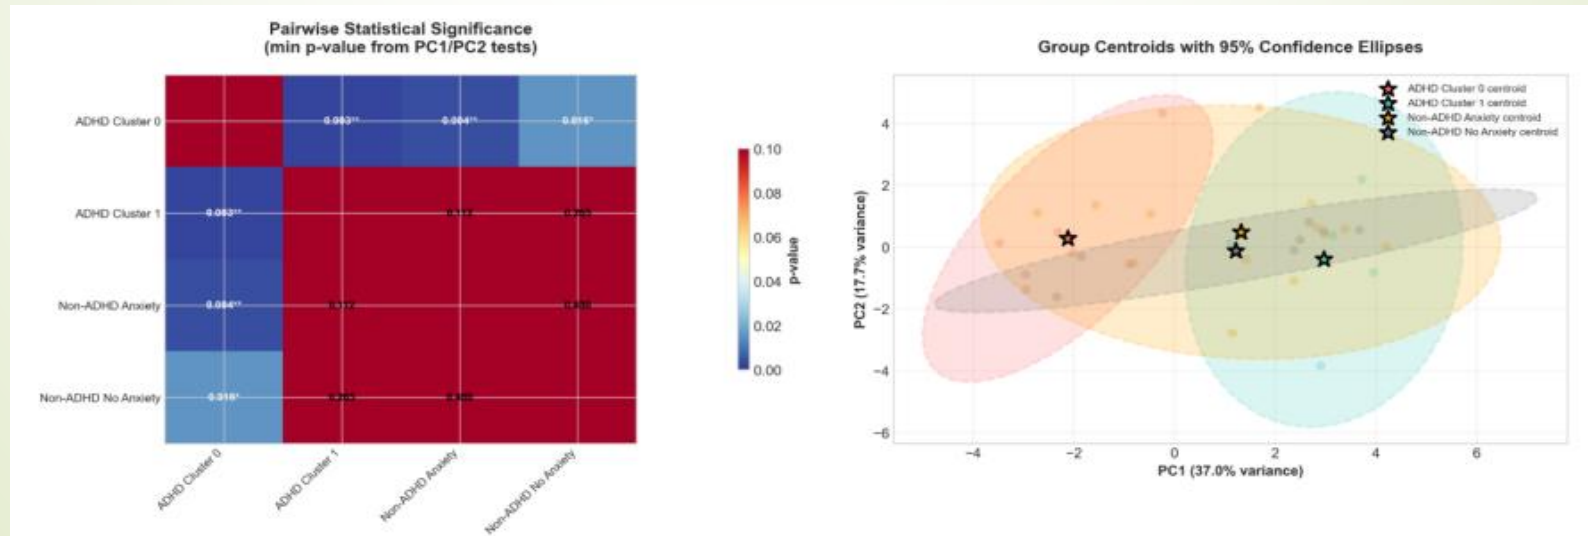
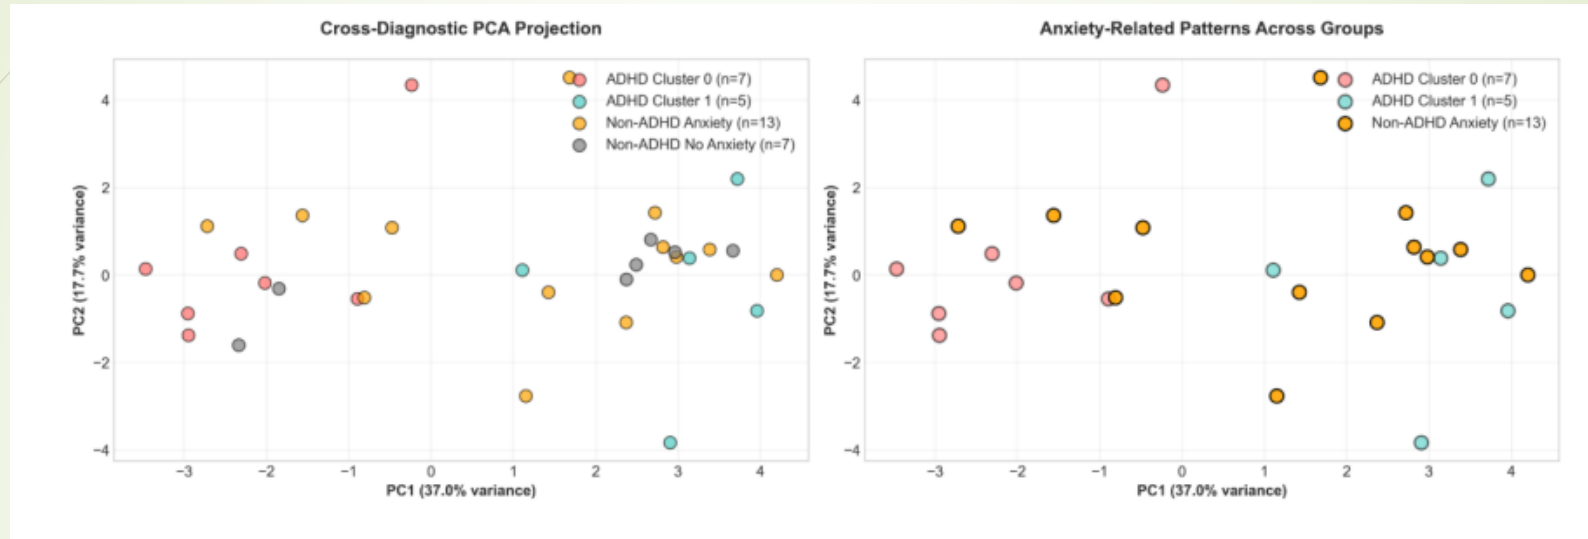


### Bootstrap Analysis of ADHD Cluster Characteristics Statistical Validation of Subtype Differences

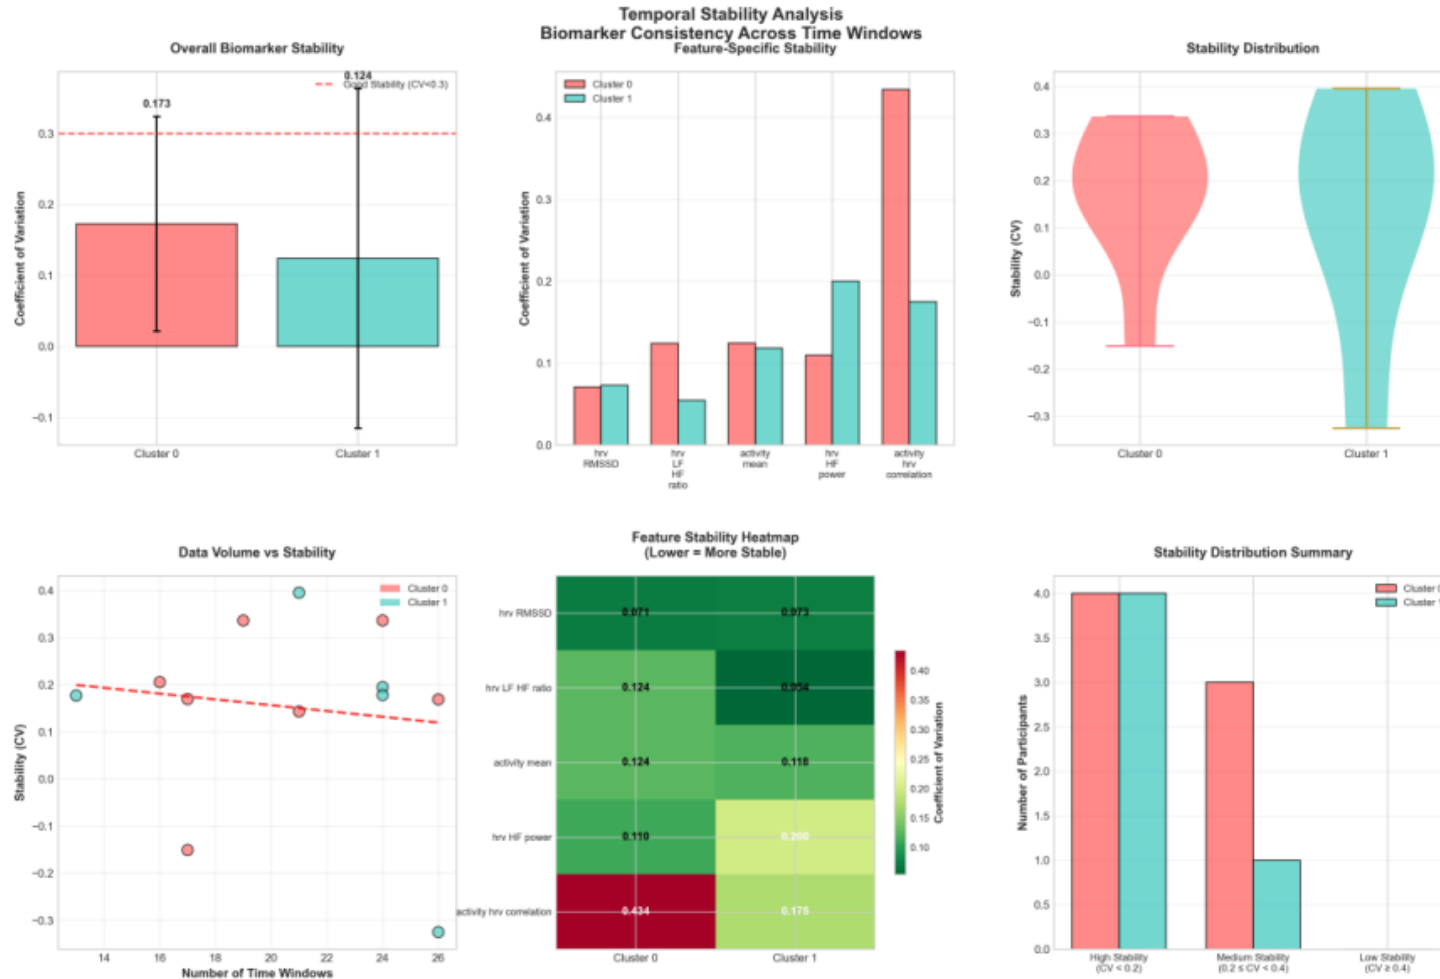




# Γενίκευση σε Διαγνωστικό Επίπεδο



# Ανάλυση Χρονικής Σταθερότητας Βιοδεικτών



# Συμπεράσματα

- Το σενάριο CPT-II + Actigraphy έδωσε υψηλότερη απόδοση
- Το HRV + Actigraphy είχε χαμηλότερες επιδόσεις, αλλά πρόσθεσε φυσιολογική διάσταση
- Το Feature Selection βελτίωσε ερμηνευσιμότητα χωρίς απώλεια απόδοσης
- Οι αλγόριθμοι (Random Forest, XGBoost, Gradient Boosting) υπερέχουν των απλών μοντέλων
- Στο Clustering με K-means στο σενάριο HRV + Actigraphy αναδείχθηκαν δύο clusters με μερική επικάλυψη
- Ενδείξεις ύπαρξης υποτύπων εντός ADHD και Controls
- PCA visualization → διαφοροποίηση με βάση HRV + δραστηριότητα



# Περιορισμοί & Μέλλον

## ► Περιορισμοί

- Μικρό μέγεθος δείγματος → περιορισμένη γενίκευση
- Cross-sectional σχεδιασμός (μία χρονική στιγμή, όχι διαχρονικά δεδομένα)
- Χρήση συγκεκριμένων αλγορίθμων → πιθανή υποεκτίμηση μη γραμμικών προτύπων
- Feature selection βασισμένο μόνο σε RFE

## ► Μελλοντικά

- Ενοποίηση περισσότερων πηγών δεδομένων (π.χ. EEG, fMRI)
- Χρήση μεγαλύτερων, διαπολιτισμικών δειγμάτων
- Ανάπτυξη ερμηνεύσιμων μοντέλων (explainable AI)
- Διερεύνηση διαχρονικών δεδομένων (longitudinal μελέτες)

Ευχαριστώ