



ΠΑΝΕΠΙΣΤΗΜΙΟ ΔΥΤΙΚΗΣ ΑΤΤΙΚΗΣ

ΣΧΟΛΗ ΜΗΧΑΝΙΚΩΝ  
ΤΜΗΜΑ ΜΗΧΑΝΙΚΩΝ ΒΙΟΪΑΤΡΙΚΗΣ

**Ο ρόλος της μηχανικής μάθησης στην  
πρόβλεψη νευρολογικών αποτελεσμάτων  
από δεδομένα ενδοεγχειρητικής  
νευροπαρακολούθησης**

**ΟΝΟΜΑΤΕΠΩΝΥΜΟ ΦΟΙΤΗΤΗ**

**Πρίλο Γιωργάκη**

**Αριθμός Μητρώου: 18388028**

**Επιβλέπων Καθηγητής**

**Παντελεήμων Ασβεστάς, Καθηγητής**

**Αθήνα 03/10/2024**

Ο ΡΟΛΟΣ ΤΗΣ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ ΣΤΗΝ ΠΡΟΒΛΕΨΗ ΝΕΥΡΟΛΟΓΙΚΩΝ ΑΠΟΤΕΛΕΣΜΑΤΩΝ ΑΠΟ  
ΔΕΔΟΜΕΝΑ ΕΝΔΟΕΓΧΕΙΡΗΤΙΚΗΣ ΝΕΥΡΟΠΑΡΑΚΟΛΟΥΘΗΣΗΣ

Η Τριμελής Εξεταστική Επιτροπή

Ο Επιβλέπων Καθηγητής

Παντελεήμων Ασβεστάς  
Καθηγητής

[ΨΗΦΙΑΚΗ ΥΠΟΓΡΑΦΗ]

Δημήτριος Γκλώτσος  
Καθηγητής

[ΨΗΦΙΑΚΗ ΥΠΟΓΡΑΦΗ]

Σπυρίδων Κωστόπουλος  
Αναπληρωτής Καθηγητής

[ΨΗΦΙΑΚΗ ΥΠΟΓΡΑΦΗ]

**ΔΗΛΩΣΗ ΣΥΓΓΡΑΦΕΑ ΔΙΠΛΩΜΑΤΙΚΗΣ ΕΡΓΑΣΙΑΣ**

Ο υπογράφων Πρίλο Γιωργάκη του Ηλία, με αριθμό μητρώου 18388028 φοιτητή του Τμήματος Μηχανικών Βιοιατρικής Σχολής Μηχανικών του Πανεπιστημίου Δυτικής Αττικής, δηλώνω υπεύθυνα ότι:

«Είμαι συγγραφέας αυτής της διπλωματικής εργασίας και κάθε βοήθεια την οποία είχα για την προετοιμασία της είναι πλήρως αναγνωρισμένη και αναφέρεται στην εργασία. Επίσης, οι όποιες πηγές από τις οποίες έκανα χρήση δεδομένων, ιδεών ή λέξεων, είτε ακριβώς είτε παραφρασμένες, αναφέρονται στο σύνολό τους, με πλήρη αναφορά στους συγγραφείς, τον εκδοτικό οίκο ή το περιοδικό, συμπεριλαμβανομένων και των πηγών που ενδεχομένως χρησιμοποιήθηκαν από το διαδίκτυο. Επίσης, βεβαιώνω ότι αυτή η εργασία έχει συγγραφεί από μένα αποκλειστικά και αποτελεί προϊόν πνευματικής ιδιοκτησίας τόσο δικής μου, όσο και του Ιδρύματος.

Παράβαση της ανωτέρω ακαδημαϊκής μου ευθύνης αποτελεί ουσιώδη λόγο για την ανάκληση του διπλώματός μου».

Ημερομηνία 03/10/2024

Ο Δηλών

Πρίλο Γιωργάκη



## **Ευχαριστίες**

Θα ήθελα να εκφράσω τις θερμότερες ευχαριστίες μου σε όλους όσους με στήριξαν κατά τη διάρκεια της εκπόνησης της πτυχιακής μου εργασίας. Πρώτα και πάνω απ' όλα, θα ήθελα να ευχαριστήσω τον επιβλέποντα καθηγητή μου, Παντελεήμων Ασβεστά για την αμέριστη υποστήριξη, τις γνώσεις και την καθοδήγησή του καθ' όλη τη διάρκεια της ερευνητικής μου πορείας. Η υπομονή και οι πολύτιμες παρατηρήσεις του/της ήταν καθοριστικές για την ολοκλήρωση αυτής της εργασίας. Επίσης, θέλω να ευχαριστήσω την οικογένειά μου για την αδιάκοπη αγάπη και στήριξή τους σε κάθε μου βήμα. Η πίστη τους σε μένα αποτέλεσε πηγή δύναμης, ειδικά στις δύσκολες στιγμές. Τέλος, ευχαριστώ από καρδιάς όλους τους φίλους και συμφοιτητές μου, που ήταν πάντα δίπλα μου με ενθάρρυνση και κατανόηση, μοιραζόμενοι τις ίδιες ανησυχίες και φιλοδοξίες.

## Περιεχόμενα

<b>1</b>	<b>Εισαγωγή .....</b>	<b>9</b>
1.1	Στόχοι της Διπλωματικής Εργασίας.....	9
1.2	Διεγχειρητική νευροπαρακολούθηση (Intraoperative Neuromonitoring) .....	9
1.2.1	Τεχνολογικές καινοτομίες .....	11
1.2.2	Η σημασία της διεγχειρητικής νευροπαρακολούθησης στη χειρουργική .....	12
1.2.3	Προκλήσεις και περιορισμοί της διεγχειρητικής νευροπαρακολούθησης (IONM) .....	14
1.3	Εισαγωγή στη μηχανική μάθηση (ML).....	17
1.3.1	Εφαρμογές της Μηχανικής Μάθησης.....	22
1.3.2	Προκλήσεις και Μελλοντικές Κατευθύνσεις.....	24
1.3.3	Εφαρμογή της Μηχανικής Μάθησης στην Ενδοεγχειρητική Νευροπαρακολούθηση (IONM) .....	25
1.3.4	Προκλήσεις και Μελλοντικές Κατευθύνσεις.....	27
1.4	Ανάλυση μεθόδων ενδοεγχειρητικής νευροπαρακολούθησης.....	28
1.4.1	Ανάλυση των Σωματοαισθητικών Προκλητών Δυναμικών (SSEPs).....	28
1.4.2	Ανάλυση των Προκλητών Δυναμικών Κινητικών (MEPs).....	30
1.4.3	Ανάλυση της Ηλεκτρομυογραφίας (EMG) .....	32
1.4.4	Ανάλυση των Προκλητών Δυναμικών του Εγκεφαλικού Στελέχους (BAEPs) .	34
1.4.5	Ανάλυση των οπτικά προκλητών δυναμικών (VEP).....	36
1.4.6	Ανάλυση δέλτα κύμα (D wave) .....	37
1.5	Εφαρμογές της μηχανικής μάθησης στην ιατρική.....	38
1.5.1	Εφαρμογές της ML στην ιατρική απεικόνιση.....	38
1.5.2	Τεχνικές που χρησιμοποιούνται στην ML για την ιατρική απεικόνιση .....	39
1.5.3	Οφέλη της ML στην ιατρική απεικόνιση .....	40
1.5.4	Προβλεπτική ανάλυση και διάγνωση ασθενειών με χρήση μηχανικής μάθησης .....	41
1.5.5	Γονιδιωματική και εξατομικευμένη ιατρική με χρήση μηχανικής μάθησης ..	44
1.6	Εφαρμογές της μηχανικής μάθησης στην ενδοεγχειρητική νευροπαρακολούθηση .....	47
1.6.1	Μελέτη 1: Εφαρμογή της μηχανικής μάθησης στην IONM για τη χειρουργική της σπονδυλικής στήλης(39) .....	47
1.6.2	Μελέτη 2: Μηχανική μάθηση για ταξινόμηση σημάτων στην ενδοεγχειρητική νευροπαρακολούθηση (IONM) .....	49
1.6.3	Μελέτη 3 Ποσοτικός προσδιορισμός κοιλιακών/ραχιαίων νεύρων μέσω διεγχειρητικής νευροφυσιολογικής παρακολούθησης με επιβλεπόμενη μηχανική μάθηση .....	51

1.6.4	Μελέτη 4: Ευκαιρίες και προκλήσεις της επιβλεπόμενης μηχανικής μάθησης για την ταξινόμηση των κινητικών προκλητών δυναμικών ανάλογα με τους μύες .....	53
<b>2</b>	<b>Μεθοδολογία .....</b>	<b>55</b>
2.1	Περιγραφή των δεδομένων IONM .....	55
2.2	Εξαγωγή χαρακτηριστικών .....	56
2.3	Εξισορρόπηση Δεδομένων .....	64
2.4	Επιλογή Χαρακτηριστικών.....	66
2.5	Υπερπαράμετροι .....	67
2.5.1	Επιλογή Παραμέτρων για KNN.....	67
2.5.2	Επιλογή Παραμέτρων για SVM .....	68
2.5.3	Επιλογή Παραμέτρων για Logistic Regression .....	69
2.5.4	Παραμέτρων για Neural Network .....	70
2.6	Διασταυρούμενη Επικύρωση (Cross-Validation) .....	72
2.6.1	Cross-Validation naive bayes.....	73
2.7	Αξιολόγηση μοντέλων .....	74
<b>3</b>	<b>Αποτελέσματα.....</b>	<b>79</b>
3.1	Εισαγωγή στα αποτελέσματα .....	79
3.2	Παρουσίαση των αποτελεσμάτων για κάθε μοντέλο μηχανικής μάθησης.....	79
3.2.1	Αποτελέσματα KNN .....	79
3.2.2	Αποτελέσματα Naive Bayes.....	81
3.2.3	Αποτελέσματα SVM.....	83
3.2.4	Αποτελέσματα Logistic Regression .....	84
3.2.5	Αποτελέσματα Neural Network .....	86
<b>4</b>	<b>Συμπεράσματα.....</b>	<b>88</b>
4.1	Σύγκριση μοντέλων .....	88
4.2	Σύγκριση μοντέλων AUC .....	89
4.3	Σύγκριση μοντέλων Confusion Matrix .....	89
4.4	Σύγκριση με άλλες μελέτες .....	89
4.5	Επιπτώσεις των ευρημάτων στην Ενδοεγχειρητική Νευροπαρακολούθηση (IONM) 90	
4.6	Περιορισμοί της μελέτης σας.....	91
4.7	Πιθανές βελτιώσεις και μελλοντικές εργασίες .....	93
<b>5</b>	<b>Επίλογος.....</b>	<b>94</b>
	<b>Βιβλιογραφία.....</b>	<b>95</b>
	<b>Παράρτημα - Κώδικας .....</b>	<b>100</b>

## Περίληψη

Η ενσωμάτωση της μηχανικής μάθησης (ML) στην διεγχειρητική νευροπαρακολούθηση (IONM) αποτελεί σημαντική πρόοδο στη χειρουργική ασφάλεια και τα αποτελέσματα των ασθενών. Η παρούσα διατριβή διερευνά την εφαρμογή διαφόρων τεχνικών ML, συμπεριλαμβανομένων των KNN, SVM, λογιστικής παλινδρόμησης, naïve Bayes και νευρωνικών δικτύων, για την ενίσχυση της ταξινόμησης και της ανάλυσης των νευροφυσιολογικών σημάτων κατά τη διάρκεια της χειρουργικής επέμβασης. Οι πρωταρχικοί στόχοι ήταν η ανάπτυξη και αξιολόγηση μοντέλων ML για την ταξινόμηση σημάτων, η σύγκριση της απόδοσης των διαφόρων αλγορίθμων και η βελτιστοποίηση των μεθόδων επιλογής χαρακτηριστικών. Η μεθοδολογία μας περιελάμβανε εκτεταμένη προεπεξεργασία δεδομένων, εξαγωγή χαρακτηριστικών και cross validation για να διασφαλιστεί η ευελιξία του μοντέλου. Τα αποτελέσματα έδειξαν ότι το μοντέλο νευρωνικού δικτύου, σε συνδυασμό με προηγμένες τεχνικές επιλογής χαρακτηριστικών, πέτυχε την υψηλότερη ακρίβεια, precision, ανάκληση και F1-score, ξεπερνώντας τις παραδοσιακές μεθόδους. Τα ευρήματα αυτά υποδηλώνουν ότι η ενισχυμένη με ML IONM μπορεί να μειώσει σημαντικά τον κίνδυνο μετεγχειρητικών νευρολογικών επιπλοκών παρέχοντας σε πραγματικό χρόνο ακριβείς εκτιμήσεις της νευρικής ακεραιότητας κατά τη διάρκεια της χειρουργικής επέμβασης. Η μελέτη υπογραμμίζει τη δυνατότητα του ML να φέρει επανάσταση στην IONM, προσφέροντας ένα ισχυρό εργαλείο για τη βελτίωση των χειρουργικών αποτελεσμάτων και της ασφάλειας των ασθενών.

Λέξεις-κλειδιά: Μηχανική Μάθηση, διεγχειρητική νευροπαρακολούθηση, ανάλυση νευροφυσιολογικών σημάτων, ηλεκτρομυογράφημα, νευρωνικά δίκτυα.

## **Abstract**

The integration of machine learning (ML) into intraoperative neuromonitoring (IONM) represents a significant advancement in surgical safety and patient outcomes. This thesis investigates the application of various ML techniques, including KNN, SVM, logistic regression, naive Bayes, and neural networks, to enhance the classification and analysis of neurophysiological signals during surgery. The primary objectives were to develop and evaluate ML models for signal classification, compare the performance of different algorithms, and optimize feature selection methods. Our methodology involved extensive data preprocessing, feature extraction, and the use of cross-validation to ensure model robustness.

The results demonstrated that the neural network model, coupled with advanced feature selection techniques, achieved the highest accuracy, precision, recall, and F1-score, outperforming traditional methods. These findings suggest that ML-enhanced IONM can significantly reduce the risk of postoperative neurological deficits by providing real-time, accurate assessments of neural integrity during surgery. The study underscores the potential of ML to revolutionize IONM, offering a powerful tool for improving surgical outcomes and patient safety.

**Keywords:** Machine Learning, Intraoperative Neuromonitoring, Neurophysiological Signal Analysis, EMG, Neural Networks.



## 1 Εισαγωγή

### 1.1 Στόχοι της Διπλωματικής Εργασίας

Ο κύριος στόχος αυτής της διπλωματικής εργασίας είναι να διερευνήσει την εφαρμογή τεχνικών μηχανικής μάθησης (ML) για τη βελτίωση της ενδοεγχειρητικής νευροπαρακολούθησης (IONM). Συγκεκριμένα, η μελέτη στοχεύει στην ανάπτυξη, αξιολόγηση και βελτιστοποίηση μοντέλων ML για την ταξινόμηση, ανάλυση και πρόβλεψη νευροφυσιολογικών σημάτων κατά τη διάρκεια της χειρουργικής επέμβασης. Χρησιμοποιώντας τη δύναμη της ML, αυτή η διπλωματική εργασία επιδιώκει να βελτιώσει την ακρίβεια, την αξιοπιστία και την αποδοτικότητα της IONM, ενισχύοντας τελικά την ασφάλεια των ασθενών και τα χειρουργικά αποτελέσματα. Ο στόχος αυτής της διπλωματικής εργασίας είναι ο εξής:

- Να αναπτυχθούν και να αξιολογηθούν διάφορα μοντέλα ML για την ταξινόμηση και ανάλυση των νευροφυσιολογικών σημάτων που συλλέγονται κατά τη διάρκεια της χειρουργικής επέμβασης.
1. **Συλλογή Δεδομένων:** Συγκέντρωση ενός ολοκληρωμένου συνόλου δεδομένων νευροφυσιολογικών σημάτων από μια ευρεία γκάμα χειρουργικών επεμβάσεων.
  2. **Προεπεξεργασία:** Προεπεξεργασία των συλλεγμένων δεδομένων για να διασφαλιστεί ότι είναι καθαρά, κανονικοποιημένα και απαλλαγμένα από τεχνουργήματα.
  3. **Εξαγωγή Χαρακτηριστικών:** Εξαγωγή σχετικών χαρακτηριστικών από τα ακατέργαστα σήματα
  4. **Μέθοδοι Επιλογής Χαρακτηριστικών:** Αξιολόγηση διάφορων μεθόδων επιλογής χαρακτηριστικών, συμπεριλαμβανομένων των μεθόδων βασισμένων σε φίλτρα, περιτυλίγματος και ενσωματωμένων μεθόδων.
  5. **Ανάπτυξη Μοντέλων:** Ανάπτυξη διαφορετικών μοντέλων ML (π.χ. νευρωνικά δίκτυα, υποστηρικτικοί διανυσματικοί μηχανισμοί (svm), δέντρα αποφάσεων) για την ταξινόμηση και ανάλυση των νευροφυσιολογικών σημάτων.
  6. **Βελτιστοποίηση Μοντέλων:** Βελτιστοποίηση των μοντέλων ML χρησιμοποιώντας τις αναγνωρισμένες τεχνικές επιλογής χαρακτηριστικών και προεπεξεργασίας
  7. **Αξιολόγηση Μοντέλων:** Αξιολόγηση της απόδοσης των αναπτυγμένων μοντέλων χρησιμοποιώντας μετρήσεις όπως η ακρίβεια, η ευαισθησία, η ειδικότητα, το F1-score
  8. **Σύγκριση:** Σύγκριση της απόδοσης των διαφορετικών μοντέλων ML για τον εντοπισμό της πιο αποτελεσματικής προσέγγισης για την ταξινόμηση και ανάλυση σημάτων.

### 1.2 Διεγχειρητική νευροπαρακολούθηση (Intraoperative Neuromonitoring)

Η διεγχειρητική νευροπαρακολούθηση (Intraoperative Neuromonitoring) είναι μια εξελιγμένη ιατρική τεχνική που χρησιμοποιείται κατά τη διάρκεια διαφόρων χειρουργικών επεμβάσεων για την παρακολούθηση της λειτουργικής ακεραιότητας νευρικών δομών όπως τα περιφερικά νεύρα, ο νωτιαίος μυελός και συγκεκριμένες περιοχές του εγκεφάλου. Ο πρωταρχικός στόχος της IONM είναι να μετριάσει τον κίνδυνο μετεγχειρητικών νευρολογικών

επιπλοκών παρέχοντας ενημέρωση σε πραγματικό χρόνο στη χειρουργική ομάδα. Αυτός ο μηχανισμός άμεσης ανατροφοδότησης επιτρέπει στους χειρουργούς να κάνουν έγκαιρες προσαρμογές στις χειρουργικές τεχνικές τους, εάν εντοπιστεί πιθανός νευρικός κίνδυνος.

Η IONM περιλαμβάνει τη χρήση νευροφυσιολογικών μεθόδων για την καταγραφή και την ανάλυση της ηλεκτρικής δραστηριότητας που παράγεται από το νευρικό σύστημα. Οι μέθοδοι αυτές περιλαμβάνουν το ηλεκτρομυογράφημα (EMG), το ηλεκτροεγκεφαλογράφημα (EEG), τα σωματοαισθητικά προκλητά δυναμικά (SSEP), τα κινητικά προκλητά δυναμικά (MEP) και τα ακουστικά προκλητά δυναμικά του εγκεφαλικού στελέχους (BAEP). Με τη συνεχή παρακολούθηση αυτών των σημάτων, η IONM μπορεί να ανιχνεύσει πρώιμα σημάδια νευρικής βλάβης, επιτρέποντας την παρέμβαση πριν από την εμφάνιση μόνιμης βλάβης. Για παράδειγμα, σε χειρουργικές επεμβάσεις σπονδυλικής στήλης, η IONM μπορεί να ειδοποιήσει τη χειρουργική ομάδα για αλλαγές στη λειτουργία του νωτιαίου μυελού, επιτρέποντας άμεσες διορθωτικές ενέργειες για την πρόληψη της παράλυσης.

Η ιστορία της διεγχειρητικής νευροπαρακολούθησης χαρακτηρίζεται από σημαντικές τεχνολογικές εξελίξεις και μια εξελισσόμενη κατανόηση της νευροφυσιολογίας. Οι απαρχές της IONM μπορούν να εντοπιστούν στις αρχές του 20ού αιώνα, αλλά μόλις στο δεύτερο μισό του αιώνα ο τομέας άρχισε να διαμορφώνεται ως κρίσιμο συστατικό της σύγχρονης χειρουργικής.

#### *Πρώιμες απαρχές:*

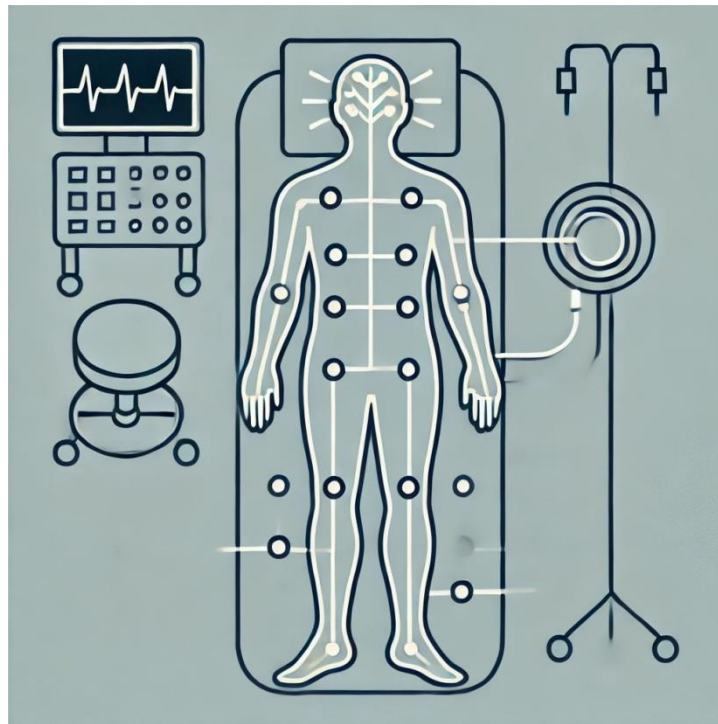
- 1920-1930: Τα αρχικά πειράματα στη νευροφυσιολογία αφορούσαν τη χρήση ηλεκτρικής διέγερσης για τη μελέτη των αντανάκλαστικών και της νευρικής αγωγιμότητας. Ερευνητές όπως οι Sherrington και Adrian διεξήγαγαν πρωτοποριακό έργο στην ηλεκτροφυσιολογία των νευρικών αποκρίσεων, το οποίο έθεσε τις βάσεις για τις μελλοντικές εξελίξεις στη νευρική παρακολούθηση.
- Δεκαετία 1950-1960: Η έλευση της ηλεκτρομυογραφίας (ΗΜΓ) παρείχε μια μέθοδο για την καταγραφή της ηλεκτρικής δραστηριότητας των μυών, προσφέροντας πληροφορίες για την ακεραιότητα των κινητικών οδών. Ταυτόχρονα, η ανάπτυξη της ηλεκτροεγκεφαλογραφίας (ΗΕΓ) επέτρεψε τη μη επεμβατική παρακολούθηση της ηλεκτρικής δραστηριότητας του εγκεφάλου, διευκολύνοντας την αξιολόγηση της εγκεφαλικής λειτουργίας κατά τη διάρκεια χειρουργικών επεμβάσεων.

#### *Ανάδυση των σύγχρονων τεχνικών:*

- 1970s: Η εισαγωγή των σωματοαισθητικών προκλητών δυναμικών (SSEP) αποτέλεσε σημαντικό ορόσημο στη IONM. Τα SSEP περιλαμβάνουν την ηλεκτρική διέγερση περιφερικών νεύρων και την καταγραφή της προκύπτουσας φλοιώδους ή υποφλοιώδους δραστηριότητας, επιτρέποντας την παρακολούθηση των αισθητικών οδών. Η εξέλιξη αυτή ήταν ζωτικής σημασίας για τις χειρουργικές επεμβάσεις στη σπονδυλική στήλη, όπου η διατήρηση της αισθητηριακής λειτουργίας είναι υψίστης σημασίας(1).
- 1980s: Η ανάπτυξη των κινητικών προκλητών δυναμικών (MEP) διεύρυνε τις δυνατότητες της IONM, επιτρέποντας την αξιολόγηση της ακεραιότητας των κινητικών οδών. Τα MEPS παράγονται με διέγερση του κινητικού φλοιού και καταγραφή των μυϊκών αποκρίσεων, παρέχοντας ανατροφοδότηση σε πραγματικό χρόνο σχετικά με τη λειτουργική κατάσταση των κινητικών οδών. Αυτή η πρόοδος

ήταν ιδιαίτερα πολύτιμη σε χειρουργικές επεμβάσεις που αφορούν τον νωτιαίο μυελό και τον εγκέφαλο.

- δεκαετία του 1990-σήμερα: Η ενσωμάτωση πολλαπλών τρόπων παρακολούθησης, συμπεριλαμβανομένων του EMG, του EEG, των SSEPs, των MEPs και των BAEPs, έχει ενισχύσει σημαντικά το πεδίο εφαρμογής και την αποτελεσματικότητα της IONM. Οι τεχνολογικές εξελίξεις στην επεξεργασία σήματος, την απόκτηση δεδομένων και την υπολογιστική ισχύ έχουν βελτιώσει περαιτέρω την ακρίβεια και την αξιοπιστία των τεχνικών IONM



Εικόνα 1.1: Απλό σχήμα νευροπαρακολούθησης

### 1.2.1 Τεχνολογικές καινοτομίες

- Ψηφιακή Επεξεργασία Σήματος: Η μετάβαση από την αναλογική στην ψηφιακή επεξεργασία σήματος έφερε επανάσταση στην IONM. Τα ψηφιακά συστήματα προσφέρουν ανώτερες δυνατότητες μείωσης του θορύβου και βελτίωσης του σήματος, με αποτέλεσμα καθαρότερες και ακριβέστερες νευροφυσιολογικές καταγραφές. Αυτές οι βελτιώσεις έχουν καταστήσει ευκολότερη την ανίχνευση λεπτών αλλαγών στη νευρική λειτουργία κατά τη διάρκεια της χειρουργικής επέμβασης.
- Φορητά και ασύρματα συστήματα: Η ανάπτυξη φορητών και ασύρματων συστημάτων παρακολούθησης έχει αυξήσει την προσβασιμότητα και την ευκολία της IONM. Τα φορητά συστήματα επιτρέπουν τη μετάδοση δεδομένων σε πραγματικό χρόνο και την απομακρυσμένη παρακολούθηση, επιτρέποντας την εφαρμογή της IONM σε διάφορες χειρουργικές ρυθμίσεις, συμπεριλαμβανομένων απομακρυσμένων και περιορισμένων περιβαλλοντικών πόρων.

- Μηχανική μάθηση και τεχνητή νοημοσύνη: Οι πρόσφατες εξελίξεις στη μηχανική μάθηση (ML) και την τεχνητή νοημοσύνη (AI) υπόσχονται πολλά για το μέλλον της IONM. Οι αλγόριθμοι TN μπορούν να αναλύουν μεγάλα σύνολα δεδομένων νευροφυσιολογικών σημάτων για τον εντοπισμό μοτίβων και την πρόβλεψη αποτελεσμάτων, ενισχύοντας την ακρίβεια και την αποτελεσματικότητα της IONM. Αυτές οι τεχνολογίες μπορούν να βοηθήσουν στην ερμηνεία των σημάτων σε πραγματικό χρόνο και στη λήψη αποφάσεων, μειώνοντας το γνωστικό φορτίο των νευροφυσιολόγων και βελτιώνοντας τα αποτελέσματα των ασθενών.

Κατανοώντας την ιστορική εξέλιξη και τις τεχνολογικές καινοτομίες στην IONM, μπορούμε να εκτιμήσουμε τις εξελίξεις που έχουν καταστήσει τη σύγχρονη διεγχειρητική νευροπαρακολούθηση απαραίτητο εργαλείο για τη διασφάλιση της χειρουργικής ασφάλειας και τη βελτίωση των αποτελεσμάτων των ασθενών. Η συνεχής εξέλιξη της IONM, που καθοδηγείται από την τεχνολογική πρόοδο και την κλινική έρευνα, υπογραμμίζει τον κρίσιμο ρόλο της στη σύγχρονη χειρουργική πρακτική.

### 1.2.2 Η σημασία της διεγχειρητικής νευροπαρακολούθησης στη χειρουργική

Η διεγχειρητική νευροπαρακολούθηση (IONM) ενισχύει σημαντικά την ασφάλεια των ασθενών με τη συνεχή παρακολούθηση των νευρικών οδών και την έγκαιρη ανίχνευση τυχόν δυσμενών αλλαγών κατά τη διάρκεια των χειρουργικών επεμβάσεων. Αυτή η παρακολούθηση σε πραγματικό χρόνο συμβάλλει στον εντοπισμό και τον μετριάσμό πιθανών νευρικών τραυματισμών πριν οδηγήσουν σε μόνιμες βλάβες.

Αρκετές μελέτες έχουν τεκμηριώσει τα οφέλη της IONM στην ενίσχυση της ασφάλειας των ασθενών. Για παράδειγμα, μια ανάλυση από τον (2) έδειξε ότι η χρήση του IONM σε επεμβάσεις σπονδυλικής στήλης μπορεί να παρέχει βελτίωση στο 92,3% των ασθενών, ενώ στην περίπτωση που δεν χρησιμοποιείται IONM έχουμε 58,3%. Η μείωση αυτή αποδίδεται στην έγκαιρη ανίχνευση των αλλαγών στα νευρικά σήματα, η οποία επιτρέπει την άμεση λήψη διορθωτικών μέτρων κατά τη διάρκεια της χειρουργικής επέμβασης.

Σε χειρουργικές επεμβάσεις που αφορούν τον νωτιαίο μυελό, όπως η διόρθωση της σκολίωσης ή η αποσυμπίεση της σπονδυλικής στήλης, το IONM διαδραματίζει κρίσιμο ρόλο στην πρόληψη των τραυματισμών του νωτιαίου μυελού. Η χρήση σωματοαισθητικών προκλητών δυναμικών (SSEP) και κινητικών προκλητών δυναμικών (MEP) επιτρέπει τη συνεχή αξιολόγηση των αισθητικών και κινητικών οδών. Εάν εντοπιστούν σημαντικές αλλαγές στα σήματα αυτά, η χειρουργική ομάδα μπορεί να τροποποιήσει την προσέγγισή της για να αποφύγει μόνιμες βλάβες. Αυτή η προληπτική προσέγγιση ενισχύει σημαντικά τη συνολική ασφάλεια της επέμβασης.

Ένα από τα πιο κρίσιμα πλεονεκτήματα του IONM είναι η ικανότητά του να παρέχει ανατροφοδότηση σε πραγματικό χρόνο στη χειρουργική ομάδα. Αυτές οι άμεσες πληροφορίες είναι ανεκτίμητες κατά τη διάρκεια πολύπλοκων χειρουργικών επεμβάσεων, επιτρέποντας στους χειρουργούς να προσαρμόζουν τις τεχνικές τους εν κινήσει για να αποτρέψουν πιθανές βλάβες στις νευρικές δομές. Η παρακολούθηση σε πραγματικό χρόνο διασφαλίζει την άμεση αντιμετώπιση τυχόν ενδείξεων νευρικής βλάβης, ελαχιστοποιώντας έτσι τον κίνδυνο μακροχρόνιων νευρολογικών ελλειμμάτων.

Για παράδειγμα, κατά τη διάρκεια χειρουργικής επέμβασης στη σπονδυλική στήλη, η παρακολούθηση των SSEP σε πραγματικό χρόνο μπορεί να προειδοποιήσει τον χειρουργό

για πιθανή βλάβη του νωτιαίου μυελού. Εάν ανιχνευθεί μείωση των σημάτων SSEP, αυτό υποδεικνύει ότι οι αισθητικές οδοί βρίσκονται σε κίνδυνο, προτρέποντας τον χειρουργό να λάβει άμεσα διορθωτικά μέτρα, όπως η προσαρμογή των χειρουργικών εργαλείων ή η μείωση της πίεσης στο νωτιαίο μυελό. Παρομοίως, κατά τη διάρκεια χειρουργικών επεμβάσεων στον εγκέφαλο, η συνεχής παρακολούθηση του EEG και των MEP παρέχει άμεση ανατροφοδότηση σχετικά με τη λειτουργική κατάσταση του εγκεφάλου και των κινητικών οδών, επιτρέποντας στη χειρουργική ομάδα να λαμβάνει τεκμηριωμένες αποφάσεις και να αποφεύγει κρίσιμες περιοχές.

Η ανατροφοδότηση σε πραγματικό χρόνο είναι επίσης απαραίτητη σε επεμβάσεις που αφορούν τα περιφερικά νεύρα. Για παράδειγμα, σε χειρουργικές επεμβάσεις για την αποκατάσταση τραυματισμών περιφερικών νεύρων, η παρακολούθηση του EMG μπορεί να ανιχνεύσει ακούσιους χειρισμούς των νεύρων, επιτρέποντας στον χειρουργό να προσαρμόσει την τεχνική του και να αποτρέψει περαιτέρω βλάβες. Αυτή η δυνατότητα άμεσης αντίδρασης ενισχύει σημαντικά την ακρίβεια και την ασφάλεια της χειρουργικής διαδικασίας.

Εκτός από την ενίσχυση της ασφάλειας των ασθενών, η IONM συμβάλλει στη βελτίωση των χειρουργικών αποτελεσμάτων διασφαλίζοντας τη διατήρηση της νευρικής λειτουργίας. Προλαμβάνοντας την ενδοεγχειρητική νευρική βλάβη, το IONM συμβάλλει στη μείωση των μετεγχειρητικών επιπλοκών, στη βελτίωση των χρόνων ανάρρωσης και στη βελτίωση της συνολικής ικανοποίησης των ασθενών. Η χρήση του IONM έχει συσχετιστεί με καλύτερα λειτουργικά αποτελέσματα και υψηλότερη ποιότητα ζωής για τους ασθενείς που υποβάλλονται σε πολύπλοκες χειρουργικές επεμβάσεις.

Μελέτες περιπτώσεων και κλινικές δοκιμές έχουν δείξει ότι οι ασθενείς που παρακολουθούνται με IONM κατά τη διάρκεια της χειρουργικής επέμβασης έχουν καλύτερα λειτουργικά αποτελέσματα σε σύγκριση με εκείνους που δεν παρακολουθούνται. Για παράδειγμα, μια μελέτη του (3) διαπίστωσε ότι οι ασθενείς που υποβλήθηκαν σε χειρουργική επέμβαση σπονδυλοδεσίας με IONM είχαν σημαντικά χαμηλότερα ποσοστά μετεγχειρητικών κινητικών ελλειμμάτων και μικρότερη παραμονή στο νοσοκομείο σε σύγκριση με εκείνους που δεν είχαν IONM. Ομοίως, σε επεμβάσεις εκτομής όγκων στον εγκέφαλο, η χρήση IONM έχει αποδειχθεί ότι μειώνει τη συχνότητα εμφάνισης μετεγχειρητικών νευρολογικών διαταραχών και βελτιώνει το συνολικό ποσοστό επιτυχίας της επέμβασης.

Επιπλέον, η IONM διευκολύνει πιο ακριβείς και στοχευμένες χειρουργικές επεμβάσεις. Παρέχοντας συνεχή ανατροφοδότηση σχετικά με τη λειτουργική κατάσταση των νευρικών δομών, το IONM επιτρέπει στους χειρουργούς να εκτελούν πιο λεπτές και ακριβείς τομές, μειώνοντας την πιθανότητα άσκοπης βλάβης των γύρω ιστών. Αυτή η ακρίβεια μεταφράζεται σε λιγότερες επιπλοκές, ταχύτερους χρόνους ανάρρωσης και καλύτερα συνολικά αποτελέσματα για τους ασθενείς.

Εκτός από τον άμεσο αντίκτυπο της στα χειρουργικά αποτελέσματα, η IONM έχει επίσης σημαντικά οικονομικά οφέλη. Μειώνοντας τη συχνότητα εμφάνισης μετεγχειρητικών επιπλοκών και συντομεύοντας τη διάρκεια παραμονής στο νοσοκομείο, το IONM συμβάλλει στη μείωση του κόστους υγειονομικής περίθαλψης. Οι ασθενείς που αναρρώνουν ταχύτερα και με λιγότερες επιπλοκές απαιτούν λιγότερη μετεγχειρητική φροντίδα και αποκατάσταση, με αποτέλεσμα την εξοικονόμηση κόστους τόσο για τους ασθενείς όσο και για τους παρόχους υγειονομικής περίθαλψης.

### **1.2.3 Προκλήσεις και περιορισμοί της διεγχειρητικής νευροπαρακολούθησης (IONM)**

#### ***Τεχνικές προκλήσεις***

Η εγκατάσταση και η συντήρηση του εξοπλισμού διεγχειρητικής νευροπαρακολούθησης (IONM) ενέχει αρκετές τεχνικές προκλήσεις που απαιτούν υψηλό επίπεδο τεχνογνωσίας. Η πολυπλοκότητα του εξοπλισμού, συμπεριλαμβανομένων των ενισχυτών, των διεγερτών, των ηλεκτροδίων και των υπολογιστικών συστημάτων, απαιτεί ακριβή βαθμονόμηση και σχολαστική συντήρηση για να διασφαλιστεί η ακριβής και αξιόπιστη παρακολούθηση κατά τη διάρκεια της χειρουργικής επέμβασης.

#### ***Θόρυβος σήματος:***

Οι θόρυβοι σήματος αποτελούν σημαντικές τεχνικές προκλήσεις στην IONM. Η χειρουργική αίθουσα είναι ένα περιβάλλον υψηλής παρεμβολής με πολυάριθμες ηλεκτρικές συσκευές, οι οποίες μπορούν να εισάγουν θόρυβο στις νευροφυσιολογικές καταγραφές. Αυτός ο θόρυβος μπορεί να επισκιάσει τα νευρικά σήματα, καθιστώντας δύσκολη την ακριβή ερμηνεία των δεδομένων. Οι στρατηγικές για τον μετριασμό του θορύβου περιλαμβάνουν τη χρήση υψηλής ποιότητας, θωρακισμένων καλωδίων, τη σωστή γείωση του εξοπλισμού και την εφαρμογή προηγμένων τεχνικών επεξεργασίας σήματος για το φιλτράρισμα του ανεπιθύμητου θορύβου.

#### ***Δυσλειτουργίες του εξοπλισμού:***

Λόγω της πολυπλοκότητας και της ευαισθησίας των συσκευών IONM μπορεί να προκύψουν δυσλειτουργίες του εξοπλισμού. Ζητήματα όπως η μετατόπιση ηλεκτροδίων, οι βλάβες υλικού και οι δυσλειτουργίες λογισμικού μπορούν να διαταράξουν τη διαδικασία παρακολούθησης, θέτοντας ενδεχομένως σε κίνδυνο την ασφάλεια των ασθενών. Η τακτική συντήρηση, οι ενδεδειγμένες προεγχειρητικοί έλεγχοι και η διαθεσιμότητα εφεδρικού εξοπλισμού είναι απαραίτητα για την ελαχιστοποίηση του κινδύνου βλαβών του εξοπλισμού κατά τη διάρκεια της χειρουργικής επέμβασης.

#### ***Τοποθέτηση ηλεκτροδίων:***

Η ακριβής τοποθέτηση των ηλεκτροδίων είναι κρίσιμη για την αποτελεσματική IONM. Τα ηλεκτρόδια πρέπει να τοποθετούνται με ακρίβεια στο σώμα του ασθενούς, ώστε να συλλαμβάνονται τα επιθυμητά νευρικά σήματα χωρίς παρεμβολές από άλλες πηγές. Η διαδικασία αυτή μπορεί να είναι ιδιαίτερα δύσκολη σε πολύπλοκες χειρουργικές επεμβάσεις όπου η πρόσβαση σε συγκεκριμένες ανατομικές θέσεις είναι περιορισμένη. Απαιτείται εξειδικευμένο προσωπικό με βαθιά κατανόηση της νευροανατομίας και της ηλεκτροφυσιολογίας για να διασφαλιστεί η σωστή τοποθέτηση των ηλεκτροδίων.

#### ***Ερμηνεία σύνθετων νευρικών σημάτων:***

Η ερμηνεία των σύνθετων νευρικών σημάτων σε πραγματικό χρόνο αποτελεί άλλη μια σημαντική τεχνική πρόκληση. Οι νευροφυσιολόγοι πρέπει να διακρίνουν μεταξύ των σημαντικών αλλαγών στα σήματα και των τεχνουργημάτων ή των φυσιολογικών μεταβολών.

Το έργο αυτό απαιτεί σημαντική εμπειρία και τεχνογνωσία, καθώς οι λανθασμένες ερμηνείες μπορεί να οδηγήσουν σε ακατάλληλες χειρουργικές αποφάσεις. Η συνεχής εκπαίδευση και κατάρτιση των νευροφυσιολόγων είναι απαραίτητες για τη διατήρηση υψηλού επιπέδου επάρκειας στην ερμηνεία των σημάτων.

### ***Ερμηνεία σημάτων***

Η ακριβής ερμηνεία των σημάτων IONM είναι ζωτικής σημασίας για την αποτελεσματικότητα της διαδικασίας παρακολούθησης. Ωστόσο, διάφοροι παράγοντες περιπλέκουν την ερμηνεία, οδηγώντας σε πιθανά ψευδώς θετικά και ψευδώς αρνητικά αποτελέσματα.

### ***Ψευδώς θετικά***

Τα ψευδώς θετικά αποτελέσματα προκύπτουν όταν το σύστημα IONM υποδεικνύει μια πιθανή νευρική βλάβη που δεν υπάρχει στην πραγματικότητα. Αυτοί οι ψευδείς συναγερμοί μπορεί να οδηγήσουν σε περιττές διακοπές της χειρουργικής διαδικασίας, προκαλώντας καθυστερήσεις και αυξάνοντας ενδεχομένως τον κίνδυνο άλλων επιπλοκών. Τα ψευδώς θετικά αποτελέσματα μπορεί να οφείλονται σε διάφορους παράγοντες, όπως ο θόρυβος του σήματος, τα τεχνουργήματα ή οι φυσιολογικές φυσιολογικές μεταβολές που παρερμηνεύονται ως παθολογικές.

### ***Ψευδώς αρνητικά***

Τα ψευδώς αρνητικά, από την άλλη πλευρά, συμβαίνουν όταν το σύστημα IONM αποτυγχάνει να ανιχνεύσει μια πραγματική νευρική βλάβη. Αυτή η αποτυχία μπορεί να οδηγήσει σε μη ανιχνευμένη νευρική βλάβη, οδηγώντας σε μετεγχειρητικά νευρολογικά ελλείμματα. Τα ψευδώς αρνητικά αποτελέσματα μπορεί να προκύψουν από ανεπαρκή ευαισθησία σήματος, ακατάλληλη τοποθέτηση ηλεκτροδίων ή λανθασμένη ερμηνεία των σημάτων. Οι συνέπειες των ψευδώς αρνητικών αποτελεσμάτων είναι ιδιαίτερα σοβαρές, καθώς υπονομεύουν τον πρωταρχικό στόχο της IONM, που είναι η πρόληψη των νευρικών βλαβών.

### ***Ανάπτυξη αξιόπιστων μεθόδων ερμηνείας***

Η ανάπτυξη αξιόπιστων και ακριβών μεθόδων για την ερμηνεία των σημάτων είναι ζωτικής σημασίας για την αντιμετώπιση αυτών των προκλήσεων. Οι εξελίξεις στους αλγορίθμους επεξεργασίας σήματος, η μηχανική μάθηση και η τεχνητή νοημοσύνη προσφέρουν πολλά υποσχόμενες λύσεις. Αυτές οι τεχνολογίες μπορούν να βοηθήσουν τους νευροφυσιολόγους στη διάκριση μεταξύ πραγματικών νευρικών συμβάντων και τεχνουργημάτων, μειώνοντας την πιθανότητα ψευδώς θετικών και ψευδώς αρνητικών αποτελεσμάτων. Ωστόσο, η εφαρμογή αυτών των προηγμένων μεθόδων απαιτεί σημαντικούς υπολογιστικούς πόρους και τεχνογνωσία.

### ***Ενσωμάτωση στη χειρουργική ροή εργασίας***

Η ενσωμάτωση της IONM στη χειρουργική ροή εργασίας παρουσιάζει υλικοτεχνικές και λειτουργικές προκλήσεις. Η αποτελεσματική ενσωμάτωση απαιτεί απρόσκοπτο συντονισμό

μεταξύ της χειρουργικής ομάδας και των νευροφυσιολόγων που είναι υπεύθυνοι για την παρακολούθηση των νευρικών σημάτων.

### ***Συντονισμός και επικοινωνία***

Ο στενός συντονισμός και η επικοινωνία μεταξύ της χειρουργικής ομάδας και των νευροφυσιολόγων είναι απαραίτητες για την επιτυχή εφαρμογή της IONM. Ο νευροφυσιολόγος πρέπει να μεταφέρει κρίσιμες πληροφορίες στον χειρουργό σε πραγματικό χρόνο, επιτρέποντας την έγκαιρη και τεκμηριωμένη λήψη αποφάσεων. Η διαδικασία αυτή απαιτεί ένα σαφώς καθορισμένο πρωτόκολλο επικοινωνίας και αμοιβαία κατανόηση των διαδικασιών IONM και των επιπτώσεών τους στη χειρουργική διαδικασία.

### ***Διοικητικές προκλήσεις***

Οι υλικοτεχνικές προκλήσεις περιλαμβάνουν την εγκατάσταση και τη διαχείριση του εξοπλισμού IONM στο χειρουργείο. Ο εξοπλισμός πρέπει να τοποθετηθεί με τρόπο που να μην παρεμβαίνει στη χειρουργική διαδικασία, εξασφαλίζοντας παράλληλα τη βέλτιστη ποιότητα σήματος. Η διάταξη αυτή μπορεί να είναι ιδιαίτερα δύσκολη σε πολυσύχναστες χειρουργικές αίθουσες όπου ο χώρος είναι περιορισμένος και διεξάγονται ταυτόχρονα πολλαπλές διαδικασίες.

### ***Κόστος και προσβασιμότητα***

Το υψηλό κόστος του εξοπλισμού IONM και η ανάγκη για εξειδικευμένη εκπαίδευση μπορεί να περιορίσουν την προσβασιμότητα και την ευρεία υιοθέτηση της IONM, ιδίως σε περιβάλλοντα περιορισμένων πόρων.

Τα συστήματα IONM είναι εξελιγμένα και ακριβά, περιλαμβάνοντας προηγμένες συσκευές νευροφυσιολογικής παρακολούθησης, λογισμικό και ηλεκτρόδια μίας χρήσης. Η αρχική επένδυση που απαιτείται για την απόκτηση και τη δημιουργία ενός συστήματος IONM μπορεί να είναι σημαντική, αποτελώντας εμπόδιο για πολλές εγκαταστάσεις υγειονομικής περίθαλψης. Επιπλέον, το συνεχές κόστος που σχετίζεται με τη συντήρηση, τη βαθμονόμηση και την αντικατάσταση των αναλωσίμων αυξάνει την οικονομική επιβάρυνση.

### ***Εξειδικευμένη εκπαίδευση***

Η αποτελεσματική χρήση του IONM απαιτεί εξειδικευμένη εκπαίδευση για τους νευροφυσιολόγους και τις χειρουργικές ομάδες. Τα προγράμματα κατάρτισης πρέπει να καλύπτουν τις τεχνικές πτυχές του εξοπλισμού IONM, την ερμηνεία των σημάτων και την ενσωμάτωση του IONM στις χειρουργικές διαδικασίες. Η ανάπτυξη και η διατήρηση αυτών των εκπαιδευτικών προγραμμάτων απαιτεί σημαντικούς πόρους και η διαθεσιμότητα εκπαιδευμένου προσωπικού μπορεί να είναι περιορισμένη, ιδίως σε αγροτικές περιοχές ή σε περιοχές με ελλειπείς πόρους.

### ***Προσβασιμότητα σε ρυθμίσεις με περιορισμένους πόρους***



Σε περιβάλλοντα περιορισμένων πόρων, το κόστος και οι απαιτήσεις κατάρτισης της IONM μπορεί να περιορίσουν σημαντικά την προσβασιμότητά της. Η εξεύρεση οικονομικά αποδοτικών λύσεων και η ανάπτυξη εκπαιδευτικών προγραμμάτων προσαρμοσμένων στις ανάγκες αυτών των ρυθμίσεων είναι ζωτικής σημασίας για την επέκταση της χρήσης της IONM σε παγκόσμιο επίπεδο. Πρωτοβουλίες όπως οι κινητές μονάδες IONM, η τηλενευροπαρακολούθηση και οι συνεργασίες με διεθνείς οργανισμούς μπορούν να συμβάλουν στη γεφύρωση του χάσματος και να καταστήσουν την IONM πιο προσιτή.

### **Πιθανές λύσεις**

Μπορούν να χρησιμοποιηθούν διάφορες στρατηγικές για την αντιμετώπιση των προκλήσεων κόστους και προσβασιμότητας της IONM. Αυτές περιλαμβάνουν την ανάπτυξη συστημάτων IONM χαμηλότερου κόστους, τη χρήση επαναχρησιμοποιήσιμων ηλεκτροδίων και την εφαρμογή τεχνολογιών τηλεϊατρικής για την παροχή υποστήριξης και εκπαίδευσης από απόσταση. Επιπλέον, οι συνεργασίες με ακαδημαϊκά ιδρύματα και οργανισμούς υγειονομικής περίθαλψης μπορούν να συμβάλουν στην ανάπτυξη και διάδοση βέλτιστων πρακτικών για την αποτελεσματική χρήση της IONM σε διάφορα περιβάλλοντα

## **1.3 Εισαγωγή στη μηχανική μάθηση (ML)**

Η μηχανική μάθηση (ML) είναι ένα υποσύνολο της τεχνητής νοημοσύνης (AI) που επικεντρώνεται στην ανάπτυξη αλγορίθμων και στατιστικών μοντέλων που επιτρέπουν στους υπολογιστές να εκτελούν εργασίες χωρίς ρητές οδηγίες. Αντί να βασίζονται σε σκληρά κωδικοποιημένους κανόνες, τα συστήματα ML μαθαίνουν από τα δεδομένα για να εντοπίζουν μοτίβα, να λαμβάνουν αποφάσεις και να προβλέπουν αποτελέσματα με μεγάλη ακρίβεια. Η ανάπτυξη της ML έχει τροφοδοτηθεί από την πρόοδο της υπολογιστικής ισχύος, τη διαθεσιμότητα τεράστιων ποσοτήτων δεδομένων και την ανάπτυξη εξελιγμένων αλγορίθμων.


Η μηχανική μάθηση περιλαμβάνει τη χρήση αλγορίθμων που μπορούν να μαθαίνουν από δεδομένα και να κάνουν προβλέψεις ή αποφάσεις με βάση αυτά. Πρόκειται για μια μέθοδο ανάλυσης δεδομένων που αυτοματοποιεί τη δημιουργία αναλυτικών μοντέλων, επιτρέποντας στα συστήματα να μαθαίνουν και να βελτιώνονται από την εμπειρία χωρίς να είναι ρητά προγραμματισμένα να εκτελούν συγκεκριμένες εργασίες(4)

### **Βασικές έννοιες:**

- **Αλγόριθμοι:** Στην καρδιά της ML βρίσκονται οι αλγόριθμοι, οι οποίοι είναι βήμα προς βήμα υπολογιστικές διαδικασίες που χρησιμοποιούνται για την επεξεργασία δεδομένων, την κατασκευή μοντέλων και την πρόβλεψη. Οι συνήθεις αλγόριθμοι ML περιλαμβάνουν δέντρα αποφάσεων, μηχανές διανυσμάτων υποστήριξης (SVM), νευρωνικά δίκτυα και αλγόριθμους ομαδοποίησης.
- **Εκπαίδευση και δοκιμή:** Τα μοντέλα ML συνήθως εκπαιδεύονται σε ένα σύνολο δεδομένων, όπου ο αλγόριθμος μαθαίνει μοτίβα και σχέσεις από τα δεδομένα. Στη συνέχεια, το εκπαιδευμένο μοντέλο δοκιμάζεται σε ένα ξεχωριστό σύνολο δεδομένων για την αξιολόγηση της απόδοσης και της γενικευσιμότητάς του.
- **Χαρακτηριστικά (features) και ετικέτες (labels):** Στην επιβλεπόμενη μάθηση, τα χαρακτηριστικά αναφέρονται στις μεταβλητές εισόδου που χρησιμοποιούνται για

την πραγματοποίηση προβλέψεων, ενώ οι ετικέτες είναι οι μεταβλητές εξόδου ή ο στόχος που το μοντέλο στοχεύει να προβλέψει.

- **Υπερπροσαρμογή (overfitting) και υποπροσαρμογή (underfitting):** Η υπερπροσαρμογή συμβαίνει όταν ένα μοντέλο μαθαίνει τα δεδομένα εκπαίδευσης πολύ καλά, συλλαμβάνοντας το θόρυβο μαζί με το υποκείμενο πρότυπο, με αποτέλεσμα κακή απόδοση σε νέα δεδομένα. Η υποπροσαρμογή συμβαίνει όταν ένα μοντέλο είναι πολύ απλό για να συλλάβει το υποκείμενο μοτίβο στα δεδομένα, οδηγώντας σε κακή απόδοση τόσο στα δεδομένα εκπαίδευσης όσο και στα νέα δεδομένα.
- **Υπερπαράμετροι (Hyperparameters):** Αυτές είναι οι παράμετροι του αλγορίθμου μάθησης που ορίζονται πριν ξεκινήσει η διαδικασία μάθησης. Παραδείγματα περιλαμβάνουν τον ρυθμό εκμάθησης στα νευρωνικά δίκτυα και τον αριθμό γειτόνων στον αλγόριθμο KNN. Η ρύθμιση των υπερπαραμέτρων (Hyperparameters tuning) είναι κρίσιμη για τη βελτιστοποίηση της απόδοσης του μοντέλου.



Εικόνα 1.2: Διαδικασία μηχανικής μάθησης(5)

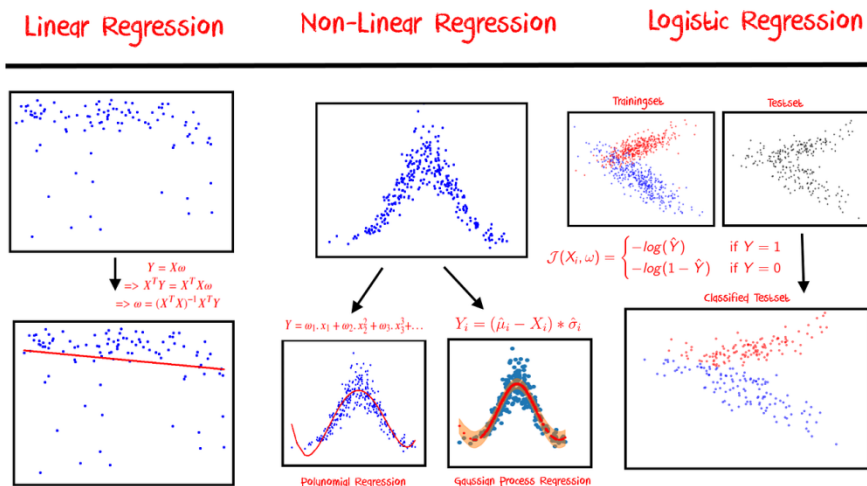
### Τεχνικές Μηχανικής Μάθησης

- **Επιβλεπόμενη Μάθηση:** Στην επιβλεπόμενη μάθηση, το μοντέλο εκπαιδεύεται σε δεδομένα με ετικέτες, δηλαδή κάθε παράδειγμα εκπαίδευσης συνοδεύεται από μια ετικέτα εξόδου. Ο στόχος είναι να μάθει να αντιστοιχίζει τις εισόδους με τις εξόδους ώστε να μπορεί να κάνει προβλέψεις σε νέα, άγνωστα δεδομένα. Κοινές εργασίες επιβλεπόμενης μάθησης περιλαμβάνουν την ταξινόμηση (classification) και την παλινδρόμηση (regression).
- **Ταξινόμηση:** Η εργασία πρόβλεψης μιας διακριτής ετικέτας για μια είσοδο. Παραδείγματα περιλαμβάνουν την ανίχνευση ανεπιθύμητης αλληλογραφίας σε email, τη διάγνωση ασθενειών με βάση την ιατρική απεικόνιση και την ανάλυση συναισθημάτων σε κείμενα.

- **Παλινδρόμηση:** Η εργασία πρόβλεψης μιας συνεχιζόμενης τιμής για μια είσοδο. Παραδείγματα περιλαμβάνουν την πρόβλεψη των τιμών των κατοικιών, των τάσεων της χρηματιστηριακής αγοράς και των ποσοστών επιβίωσης ασθενών.
- **Ανεπίβλεπτη Μάθηση:** Στην ανεπίβλεπτη μάθηση, το μοντέλο εκπαιδεύεται σε δεδομένα χωρίς ετικέτες, δηλαδή τα δεδομένα εκπαίδευσης αποτελούνται από εισόδους χωρίς σχετικές ετικέτες εξόδου. Ο στόχος είναι να βρει κρυμμένα μοτίβα ή δομές στα δεδομένα. Κοινές εργασίες ανεπίβλεπτης μάθησης περιλαμβάνουν τη συγκέντρωση (clustering) και τη μείωση διαστάσεων (dimensionality reduction).
- **Συσταδοποίηση (Clustering):** Η εργασία ομαδοποίησης παρόμοιων σημείων δεδομένων με βάση τα χαρακτηριστικά τους. Παραδείγματα περιλαμβάνουν την τμηματοποίηση πελατών στο μάρκετινγκ, την ομαδοποίηση γονιδίων με παρόμοια πρότυπα έκφρασης και την ανίχνευση ανωμαλιών στην κυκλοφορία δικτύου.
- **Μείωση Διαστάσεων (Dimensionality Reduction):** Η εργασία μείωσης του αριθμού των χαρακτηριστικών στα δεδομένα, διατηρώντας όσο το δυνατόν περισσότερη πληροφορία. Τεχνικές όπως η ανάλυση κύριων συνιστωσών (PCA) και το t-SNE χρησιμοποιούνται για αυτό το σκοπό.
- **Ενισχυτική Μάθηση (Reinforcement Learning):** Η ενισχυτική μάθηση περιλαμβάνει την εκπαίδευση ενός παράγοντα να παίρνει μια σειρά αποφάσεων αλληλεπιδρώντας με ένα περιβάλλον. Ο παράγοντας λαμβάνει ανταμοιβές ή ποινές με βάση τις ενέργειές του και μαθαίνει να βελτιστοποιεί τη συμπεριφορά του για να μεγιστοποιήσει τις συνολικές ανταμοιβές. Η ενισχυτική μάθηση χρησιμοποιείται ευρέως στη ρομποτική, στα παιχνίδια και στα αυτόνομα συστήματα.
- **Ημι-επιβλεπόμενη Μάθηση (Semi-supervised Learning):** Η ημι-επιβλεπόμενη μάθηση βρίσκεται μεταξύ της επιβλεπόμενης και της ανεπίβλεπτης μάθησης. Περιλαμβάνει την εκπαίδευση ενός μοντέλου σε ένα μικρό ποσό δεδομένων με ετικέτες, συμπληρωμένα με μεγάλο όγκο δεδομένων χωρίς ετικέτες. Αυτή η προσέγγιση εκμεταλλεύεται τα πλεονεκτήματα και των δύο μεθόδων και είναι ιδιαίτερα χρήσιμη όταν η απόκτηση δεδομένων με ετικέτες είναι δαπανηρή ή χρονοβόρα.
- **Αυτοεπιβλεπόμενη Μάθηση (Self-supervised Learning):** Η αυτοεπιβλεπόμενη μάθηση είναι ένας τύπος ανεπίβλεπτης μάθησης όπου τα δεδομένα παρέχουν την εποπτεία. Το μοντέλο μαθαίνει να προβλέπει μέρος της εισόδου από άλλα μέρη. Αυτή η προσέγγιση χρησιμοποιείται συνήθως σε εργασίες επεξεργασίας φυσικής γλώσσας (NLP), όπως η μοντελοποίηση γλώσσας και η δημιουργία κειμένων.


#### **Μοντέλα Μηχανικής Μάθησης**

- **Ανάλυση Παλινδρόμησης (Regression Analysis):** Η ανάλυση παλινδρόμησης περιλαμβάνει την εκτίμηση των σχέσεων μεταξύ των μεταβλητών. Χρησιμοποιείται για να προβλέψει μια συνεχιζόμενη μεταβλητή εξόδου με βάση μία ή περισσότερες μεταβλητές πρόβλεψης. Κοινές τεχνικές παλινδρόμησης περιλαμβάνουν τη γραμμική παλινδρόμηση, την πολυωνυμική παλινδρόμηση και την λογιστική παλινδρόμηση.



Εικόνα 1.3: Μοντέλα παλινδρόμησης(6)

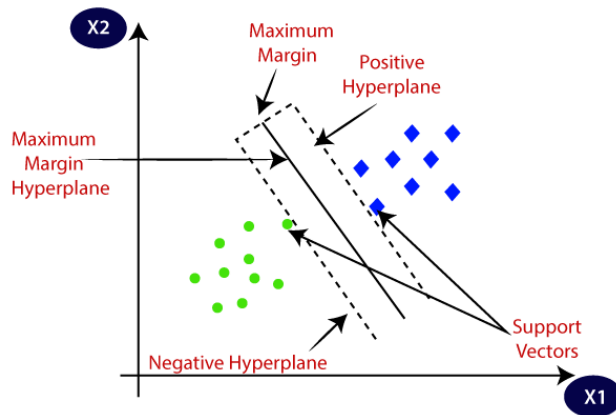
- **Δέντρα Απόφασης (Decision Trees):** Τα δέντρα απόφασης είναι μια μη παραμετρική μέθοδος επιβλεπόμενης μάθησης που χρησιμοποιείται για ταξινόμηση και παλινδρόμηση. Μοντελοποιούν αποφάσεις και τις πιθανές συνέπειές τους ως μια δομή δέντρου. Τα δέντρα απόφασης είναι εύκολα στην ερμηνεία και μπορούν να χειριστούν τόσο αριθμητικά όσο και κατηγορηματικά δεδομένα.



Εικόνα 1.4: Διάγραμμα τυχαίων δέντρων


- **Τυχαία δάση(random forest):** λειτουργεί με την κατασκευή πολλαπλών δέντρων απόφασης κατά την εκπαίδευση και την εξαγωγή του τρόπου των κλάσεων (ταξινόμηση) ή της μέσης πρόβλεψης (παλινδρόμηση) των επιμέρους δέντρων. Πρόκειται για μια μέθοδο ensemble, που σημαίνει ότι συνδυάζει τα αποτελέσματα πολλαπλών μοντέλων για τη βελτίωση της ακρίβειας και τη μείωση της υπερπροσαρμογής. Το "δάσος" στο Random Forest αποτελείται από πολλά δέντρα απόφασης, καθένα από τα οποία εκπαιδεύεται σε ένα τυχαίο υποσύνολο των δεδομένων, γεγονός που συμβάλλει στην ενίσχυση της ευρωστίας και των δυνατοτήτων γενίκευσης του μοντέλου.

- **Υποστηρικτικοί Διανυσματικοί Μηχανισμοί (SVM):** Οι υποστηρικτικοί διανυσματικοί μηχανισμοί (SVM) είναι μοντέλα επιβλεπόμενης μάθησης που χρησιμοποιούνται για εργασίες ταξινόμησης και παλινδρόμησης. Λειτουργούν βρίσκοντας το υπερεπίπεδο που διαχωρίζει καλύτερα τα δεδομένα σε διαφορετικές κατηγορίες. Οι SVM είναι αποτελεσματικοί σε χώρους υψηλής διάστασης και χρησιμοποιούνται σε εφαρμογές όπως η κατηγοριοποίηση κειμένου και η ταξινόμηση εικόνων.



Εικόνα 1.5: Svm σχεδιάγραμμα(7)

- **Νευρωνικά Δίκτυα (Neural Networks):** Τα νευρωνικά δίκτυα είναι μια κατηγορία αλγορίθμων ML εμπνευσμένα από τη δομή και τη λειτουργία του ανθρώπινου εγκεφάλου. Αποτελούνται από διασυνδεδεμένα στρώματα νευρώνων που επεξεργάζονται δεδομένα εισόδου για να μάθουν περίπλοκα μοτίβα. Η βαθιά μάθηση, ένα υποσύνολο των νευρωνικών δικτύων με πολλά κρυφά στρώματα, έχει σημειώσει αξιοσημείωτη επιτυχία σε εργασίες όπως η αναγνώριση εικόνων, η επεξεργασία ομιλίας και η κατανόηση φυσικής γλώσσας.




Εικόνα 1.6: Νευρωνικά Δίκτυα(8)

- **Βαθιά μάθηση :** επικεντρώνεται στη χρήση νευρωνικών δικτύων με πολλά επίπεδα (συνήα αποκαλούμενα βαθιά νευρωνικά δίκτυα) για τη μοντελοποίηση σύνθετων μοτίβων στα δεδομένα. Αυτά τα στρώματα μπορούν να μάθουν αυτόματα να αναπαριστούν δεδομένα σε πολλαπλά επίπεδα αφαίρεσης, καθιστώντας τη βαθιά μάθηση ιδιαίτερα ισχυρή για εργασίες όπως η αναγνώριση εικόνων, η επεξεργασία

φυσικής γλώσσας και η αναγνώριση ομιλίας. Τα μοντέλα βαθιάς μάθησης, όπως τα συνελκτικά νευρωνικά δίκτυα (CNN) και τα επαναλαμβανόμενα νευρωνικά δίκτυα (RNN), είναι εμπνευσμένα από τη δομή και τη λειτουργία του ανθρώπινου εγκεφάλου.

- **Αλγόριθμοι Συσταδοποίηση (clustering):** Οι αλγόριθμοι συγκέντρωσης ομαδοποιούν παρόμοια σημεία δεδομένων με βάση τα χαρακτηριστικά τους. Κοινές τεχνικές συγκέντρωσης περιλαμβάνουν τα K-means, ιεραρχική συγκέντρωση και DBSCAN. Αυτοί οι αλγόριθμοι χρησιμοποιούνται σε διάφορες εφαρμογές, όπως η τμηματοποίηση πελατών, η ανίχνευση ανωμαλιών και η τμηματοποίηση εικόνων.



Εικόνα1.7: k-means(9)

- **Τεχνικές Μείωσης Διαστάσεων:** Οι τεχνικές μείωσης διαστάσεων χρησιμοποιούνται για να μειώσουν τον αριθμό των χαρακτηριστικών σε ένα σύνολο δεδομένων, διατηρώντας παράλληλα σημαντικές πληροφορίες. Η Ανάλυση Κύριων Συνιστωσών (PCA) και την ενσωμάτωση στοχαστικού γείτονα κατανομής t (t-SNE) είναι ευρέως χρησιμοποιούμενες μέθοδοι που βοηθούν στην οπτικοποίηση δεδομένων υψηλών διαστάσεων και στη βελτίωση της απόδοσης των μοντέλων ML.
- **Ο Πολυγονιδιακός Βαθμός Κινδύνου (PRS)** είναι ένας αριθμός που ποσοτικοποιεί τη γενετική προδιάθεση ενός ατόμου για μια συγκεκριμένη ασθένεια ή χαρακτηριστικό με βάση τη σωρευτική επίδραση πολλαπλών γενετικών παραλλαγών. Κάθε παραλλαγή συνεισφέρει ένα μικρό ποσό στο συνολικό κίνδυνο ή χαρακτηριστικό, και όταν συνδυάζονται, αυτές οι παραλλαγές μπορούν να παρέχουν μια εξατομικευμένη εκτίμηση της πιθανότητας ενός ατόμου να αναπτύξει ορισμένες παθήσεις, όπως καρδιακές παθήσεις, διαβήτη ή καρκίνο. Η PRS χρησιμοποιείται όλο και περισσότερο στην εξατομικευμένη ιατρική για την πρόβλεψη του κινδύνου εμφάνισης ασθενειών και την καθοδήγηση στρατηγικών πρόληψης και θεραπείας.

### 1.3.1 Εφαρμογές της Μηχανικής Μάθησης

Η μηχανική μάθηση έχει φέρει επανάσταση σε πολλές βιομηχανίες, επιτρέποντας τη λήψη αποφάσεων βάσει δεδομένων και την αυτοματοποίηση. Ορισμένες από τις σημαντικές εφαρμογές περιλαμβάνουν:

**Υγεία:**

- **Ιατρική Απεικόνιση:** Οι αλγόριθμοι ML χρησιμοποιούνται για την ανάλυση ιατρικών εικόνων για τη διάγνωση ασθενειών και τον σχεδιασμό θεραπείας. Παραδείγματα περιλαμβάνουν την ανίχνευση όγκων σε μαγνητικές τομογραφίες (MRI), την αναγνώριση καταγμάτων σε ακτινογραφίες και τη διάγνωση ασθενειών του αμφιβληστροειδούς από εικόνες ματιών.
- **Προβλεπτική Αναλυτική:** Τα μοντέλα ML προβλέπουν τα αποτελέσματα των ασθενών, τα ποσοστά επανεγχείρησης και την εξέλιξη των ασθενειών, βοηθώντας στην έγκαιρη παρέμβαση και στην εξατομικευμένη θεραπεία.
- **Ανακάλυψη Φαρμάκων:** Η ML επιταχύνει την ανακάλυψη φαρμάκων προβλέποντας τις μοριακές ιδιότητες, αναγνωρίζοντας πιθανά υποψήφια φάρμακα και βελτιστοποιώντας τις φόρμουλες των φαρμάκων(10).

#### Οικονομικά:

- **Ανίχνευση Απάτης:** Οι αλγόριθμοι ML ανιχνεύουν δόλιες συναλλαγές εντοπίζοντας ασυνήθιστα μοτίβα στα δεδομένα συναλλαγών. Αυτά τα μοντέλα βοηθούν στην πρόληψη της οικονομικής απάτης και στην προστασία των καταναλωτών.
- **Αλγοριθμικό Εμπόριο:** Τα μοντέλα ML αναλύουν τα δεδομένα της αγοράς και εκτελούν συναλλαγές με βάση τις προβλεπόμενες κινήσεις των τιμών, βελτιστοποιώντας τις στρατηγικές εμπορίου και μεγιστοποιώντας τα κέρδη.
- **Αξιολόγηση Κινδύνου:** Τα μοντέλα ML αξιολογούν τον πιστωτικό κίνδυνο, τις ασφαλιστικές απαιτήσεις και τους επενδυτικούς κινδύνους αναλύοντας ιστορικά δεδομένα και αναγνωρίζοντας πιθανούς κινδύνους(11)

#### Λιανικό Εμπόριο:

- **Συστήματα Σύστασης:** Οι αλγόριθμοι ML προτείνουν προϊόντα στους πελάτες με βάση το ιστορικό περιήγησης, τα πρότυπα αγορών και τις προτιμήσεις τους. Αυτά τα συστήματα βελτιώνουν την εμπειρία του πελάτη και αυξάνουν τις πωλήσεις.
- **Διαχείριση Αποθεμάτων:** Τα μοντέλα ML προβλέπουν τη ζήτηση και βελτιστοποιούν τα επίπεδα αποθεμάτων, μειώνοντας τις ελλείψεις και ελαχιστοποιώντας το κόστος αποθήκευσης.
- **Τμηματοποίηση Πελατών:** Οι αλγόριθμοι ML τμηματοποιούν τους πελάτες σε ομάδες με βάση τη συμπεριφορά τους, επιτρέποντας στοχευμένο μάρκετινγκ και εξατομικευμένες προωθήσεις(12).

#### Βιομηχανία:

- **Προβλεπτική Συντήρηση:** Τα μοντέλα ML προβλέπουν τις βλάβες εξοπλισμού και τις ανάγκες συντήρησης αναλύοντας δεδομένα αισθητήρων και ιστορικά αρχεία, μειώνοντας τον χρόνο διακοπής και το κόστος συντήρησης.
- **Έλεγχος Ποιότητας:** Οι αλγόριθμοι ML επιθεωρούν τα προϊόντα για ελαττώματα και διασφαλίζουν ότι πληρούν τα πρότυπα ποιότητας, βελτιώνοντας την παραγωγική αποδοτικότητα και μειώνοντας τα απόβλητα.
- **Βελτιστοποίηση Εφοδιαστικής Αλυσίδας:** Τα μοντέλα ML βελτιστοποιούν τις λειτουργίες της εφοδιαστικής αλυσίδας προβλέποντας τη ζήτηση, διαχειρίζοντας τα αποθέματα και βελτιστοποιώντας την εφοδιαστική(13).

### Μεταφορές:

- **Αυτόνομα Οχήματα:** Οι αλγόριθμοι ML επιτρέπουν στα αυτοκινούμενα οχήματα να πλοηγούνται, να ανιχνεύουν εμπόδια και να παίρνουν αποφάσεις σε πραγματικό χρόνο, βελτιώνοντας την ασφάλεια και την αποδοτικότητα.
- **Βελτιστοποίηση Διαδρομών:** Τα μοντέλα ML βελτιστοποιούν τις διαδρομές και τα χρονοδιαγράμματα παραδόσεων, μειώνοντας τον χρόνο ταξιδιού και την κατανάλωση καυσίμων.
- **Διαχείριση Κυκλοφορίας:** Οι αλγόριθμοι ML αναλύουν τα μοτίβα κυκλοφορίας και βελτιστοποιούν τη ροή της κυκλοφορίας, μειώνοντας τη συμφόρηση και βελτιώνοντας την αποδοτικότητα των μεταφορών(14).

### Επεξεργασία Φυσικής Γλώσσας (NLP)

- **Ανάλυση Συναισθημάτων:** Τα μοντέλα ML αναλύουν δεδομένα κειμένου για να προσδιορίσουν τα συναισθήματα, βοηθώντας τις επιχειρήσεις να κατανοήσουν τις απόψεις των πελατών και να βελτιώσουν τα προϊόντα και τις υπηρεσίες τους.
- **Μηχανική Μετάφραση:** Οι αλγόριθμοι ML μεταφράζουν κείμενα από μια γλώσσα σε άλλη, διασπώντας τα γλωσσικά εμπόδια και διευκολύνοντας την επικοινωνία.
- **Chatbots:** Τα chatbots με ML παρέχουν υποστήριξη πελατών, απαντούν σε ερωτήσεις και αυτοματοποιούν εργασίες, βελτιώνοντας την εμπειρία του πελάτη και την επιχειρησιακή αποδοτικότητα(15).

### 1.3.2 Προκλήσεις και Μελλοντικές Κατευθύνσεις

#### Προκλήσεις:

- **Ποιότητα και Ποσότητα Δεδομένων:** Τα μοντέλα ML απαιτούν μεγάλα ποσά υψηλής ποιότητας δεδομένων για την εκπαίδευση. Τα ανεπαρκή ή χαμηλής ποιότητας δεδομένα μπορούν να οδηγήσουν σε ανακριβείς προβλέψεις και κακή απόδοση.
- **Ερμηνευσιμότητα:** Πολλά μοντέλα ML, ιδιαίτερα τα μοντέλα βαθιάς μάθησης, έχουν διαδικασίες λήψης αποφάσεων που δεν είναι εύκολα ερμηνεύσιμες. Η βελτίωση της ερμηνευσιμότητας των μοντέλων είναι κρίσιμη για την απόκτηση εμπιστοσύνης και την εξασφάλιση λογοδοσίας.
- **Ηθικές και Προσωπικές Ανησυχίες:** Η χρήση της ML εγείρει ηθικές και προσωπικές ανησυχίες, όπως η προστασία των δεδομένων και η πιθανή κακή χρήση. Η αντιμετώπιση αυτών των ανησυχιών είναι ουσιαστική για την υπεύθυνη εφαρμογή των τεχνολογιών ML.
- **Υπολογιστικοί Πόροι:** Η εκπαίδευση σύνθετων μοντέλων ML απαιτεί σημαντικούς υπολογιστικούς πόρους, οι οποίοι μπορεί να αποτελέσουν εμπόδιο για οργανισμούς με περιορισμένη πρόσβαση σε προηγμένο υλικό.

#### Μελλοντικές Κατευθύνσεις:

- **Ερμηνεύσιμη Τεχνική νοημοσύνη (XAI):** Η έρευνα στην ερμηνεύσιμη ΤΝ στοχεύει στην ανάπτυξη μοντέλων ML που είναι πιο διαφανή και ερμηνεύσιμα, ε`312`χπιτρέποντας στους χρήστες να κατανοούν και να εμπιστεύονται τις αποφάσεις των μοντέλων.



- **Ομόσπονδη Μάθηση (Federated Learning):** Η ομόσπονδη μάθηση επιτρέπει την εκπαίδευση μοντέλων ML σε αποκεντρωμένες πηγές δεδομένων χωρίς να μοιράζονται τα ακατέργαστα δεδομένα, ενισχύοντας την προστασία της ιδιωτικότητας και της ασφάλειας.
- **Μεταφορά Μάθησης (Transfer Learning):** Η μεταφορά μάθησης περιλαμβάνει τη χρήση προ-εκπαιδευμένων μοντέλων σε συναφή καθήκοντα για τη βελτίωση της απόδοσης σε νέα καθήκοντα με περιορισμένα δεδομένα. Αυτή η προσέγγιση μπορεί να μειώσει τον χρόνο εκπαίδευσης και τις απαιτήσεις σε πόρους.
- **Edge Computing:** Ο υπολογισμός αυτός φέρνει την επεξεργασία ML πιο κοντά στην πηγή των δεδομένων, μειώνοντας την καθυστέρηση και βελτιώνοντας τη λήψη αποφάσεων σε πραγματικό χρόνο. Αυτό είναι ιδιαίτερα σημαντικό για εφαρμογές όπως τα αυτόνομα οχήματα και οι συσκευές IoT.
- **Ενσωμάτωση με Άλλες Τεχνολογίες:** Η ενσωμάτωση της ML με άλλες αναδυόμενες τεχνολογίες, όπως η κβαντική υπολογιστική, το blockchain και το Διαδίκτυο των Πραγμάτων (IoT), έχει τη δυνατότητα να ξεκλειδώσει νέες δυνατότητες και εφαρμογές.

### 1.3.3 Εφαρμογή της Μηχανικής Μάθησης στην Ενδοεγχειρητική Νευροπαρακολούθηση (IONM)

Η ενσωμάτωση της μηχανικής μάθησης (ML) στην ενδοεγχειρητική νευροπαρακολούθηση (IONM) αντιπροσωπεύει μια ελπιδοφόρα εξέλιξη στον τομέα της χειρουργικής φροντίδας. Η ML έχει τη δυνατότητα να βελτιώσει την ακρίβεια, την αξιοπιστία και την αποδοτικότητα της IONM αυτοματοποιώντας την ανάλυση των σύνθετων νευροφυσιολογικών δεδομένων και παρέχοντας υποστήριξη αποφάσεων σε πραγματικό χρόνο στις χειρουργικές ομάδες. Αυτή η ενότητα εξερευνά τους διάφορους τρόπους με τους οποίους η ML μπορεί να εφαρμοστεί στην IONM, τα οφέλη που προσφέρει και τις προκλήσεις που πρέπει να αντιμετωπιστούν.

- **Βελτίωση της Ερμηνείας και της Ανάλυσης Σημάτων:** Μία από τις κύριες εφαρμογές της ML στην IONM είναι η βελτίωση της ερμηνείας και της ανάλυσης σημάτων. Η παραδοσιακή IONM βασίζεται σε μεγάλο βαθμό στην εμπειρία των νευροφυσιολόγων για την ερμηνεία σύνθετων νευροφυσιολογικών σημάτων, κάτι που μπορεί να είναι δύσκολο και χρονοβόρο. Οι αλγόριθμοι ML μπορούν να βοηθήσουν σε αυτή τη διαδικασία αναλύοντας αυτόματα τα σήματα και αναγνωρίζοντας μοτίβα που υποδηλώνουν πιθανό νευρικό τραυματισμό.
- **Ταξινόμηση Σημάτων:** Τα μοντέλα ML, ιδιαίτερα οι αλγόριθμοι βαθιάς μάθησης όπως τα συνελκτικά νευρωνικά δίκτυα (CNN), μπορούν να εκπαιδευτούν για να ταξινομήσουν διαφορετικούς τύπους νευροφυσιολογικών σημάτων, όπως EMG, EEG, SSEPs και MEPs. Αυτά τα μοντέλα μπορούν να μάθουν να διακρίνουν μεταξύ φυσιολογικών και ανώμαλων προτύπων σημάτων, μειώνοντας το φορτίο στους νευροφυσιολόγους και βελτιώνοντας την ακρίβεια της ερμηνείας των σημάτων. Για παράδειγμα, ένα CNN εκπαιδευμένο σε ένα μεγάλο σύνολο δεδομένων σημάτων EMG μπορεί να εντοπίσει λεπτές αλλαγές που μπορεί να υποδηλώνουν ερεθισμό ή βλάβη νεύρου, επιτρέποντας έγκαιρη παρέμβαση.
- **Ανίχνευση Ανωμαλιών:** Οι αλγόριθμοι ανεπίβλεπτης μάθησης, όπως οι αυτόματοι κωδικοποιητές και οι τεχνικές συγκέντρωσης, μπορούν να χρησιμοποιηθούν για την ανίχνευση ανωμαλιών στα νευροφυσιολογικά σήματα. Αυτοί οι αλγόριθμοι μπορούν να μάθουν τα φυσιολογικά μοτίβα της νευρικής δραστηριότητας κατά τη διάρκεια της χειρουργικής επέμβασης και να επισημάνουν τυχόν αποκλίσεις που μπορεί να

υποδηλώνουν πιθανά προβλήματα. Τα μοντέλα ανίχνευσης ανωμαλιών μπορούν να παρέχουν έγκαιρες προειδοποιήσεις για τον νευρικό σύστημα, επιτρέποντας στην χειρουργική ομάδα να λάβει διορθωτικά μέτρα πριν συμβεί σημαντική ζημιά.

- **Εξαγωγή Χαρακτηριστικών:** Οι αλγόριθμοι ML μπορούν να αυτοματοποιήσουν την εξαγωγή σχετικών χαρακτηριστικών από ακατέργαστα νευροφυσιολογικά δεδομένα, όπως πλάτος, λανθάνουσα περίοδο και συχνότητες σημάτων. Η εξαγωγή χαρακτηριστικών είναι ένα κρίσιμο βήμα στην ανάλυση σημάτων, καθώς βοηθά στον εντοπισμό των πιο ενημερωτικών πτυχών των σημάτων. Προχωρημένες τεχνικές ML, όπως η ανάλυση κύριων συνιστωσών (PCA) και η ανεξάρτητη ανάλυση συνιστωσών (ICA), μπορούν να χρησιμοποιηθούν για τη μείωση της διαστατικότητας των δεδομένων διατηρώντας παράλληλα σημαντικές πληροφορίες, καθιστώντας τα δεδομένα ευκολότερα στην ανάλυση και ερμηνεία.
- **Αποφάσεις σε Πραγματικό Χρόνο:** Η ML μπορεί να παρέχει υποστήριξη αποφάσεων σε πραγματικό χρόνο στις χειρουργικές ομάδες ενσωματώνοντας συστήματα IONM και προσφέροντας εφαρμόσιμες πληροφορίες με βάση την ανάλυση των νευροφυσιολογικών δεδομένων. Αυτή η δυνατότητα είναι ιδιαίτερα πολύτιμη σε περιβάλλοντα χειρουργείων υψηλού κινδύνου όπου η έγκαιρη και ακριβής λήψη αποφάσεων είναι κρίσιμη.
- **Προβλεπτική Μοντελοποίηση:** Η προβλεπτική μοντελοποίηση περιλαμβάνει τη χρήση ιστορικών δεδομένων για τη δημιουργία μοντέλων που μπορούν να προβλέψουν μελλοντικά αποτελέσματα. Στο πλαίσιο της IONM, μπορούν να αναπτυχθούν προβλεπτικά μοντέλα για την εκτίμηση της πιθανότητας νευρικού τραυματισμού με βάση τα δεδομένα παρακολούθησης σε πραγματικό χρόνο. Για παράδειγμα, ένα προβλεπτικό μοντέλο θα μπορούσε να αναλύσει τις τάσεις στα σήματα SSEP και MEP για να εκτιμήσει τον κίνδυνο τραυματισμού του νωτιαίου μυελού κατά τη διάρκεια της χειρουργικής επέμβασης σπονδυλικής στήλης. Παρέχοντας πιθανολογικές προβλέψεις, αυτά τα μοντέλα μπορούν να βοηθήσουν την χειρουργική ομάδα να αξιολογήσει το επίπεδο κινδύνου και να λάβει ενημερωμένες αποφάσεις.
- **Συστήματα Προειδοποίησης:** Τα συστήματα προειδοποίησης με ML μπορούν να ενσωματωθούν στις πλατφόρμες IONM για να παρέχουν ειδοποιήσεις σε πραγματικό χρόνο για πιθανά νευρικά προβλήματα. Αυτά τα συστήματα μπορούν να σχεδιαστούν ώστε να ενεργοποιούν ειδοποιήσεις με βάση προκαθορισμένα κατώφλια ή δυναμικά κριτήρια που έχουν μάθει από τα δεδομένα. Για παράδειγμα, αν το πλάτος ενός σήματος MEP πέσει κάτω από ένα συγκεκριμένο επίπεδο, το σύστημα προειδοποίησης θα μπορούσε να ειδοποιήσει την χειρουργική ομάδα να διερευνήσει και να αντιμετωπίσει το ζήτημα. Τέτοια συστήματα βελτιώνουν την ανταπόκριση της IONM και μειώνουν την πιθανότητα παραλειπόμενων προειδοποιήσεων.
- **Δέντρα Αποφάσεων και Συστήματα Κανόνων:** Τα δέντρα αποφάσεων και τα συστήματα κανόνων είναι απλά αλλά αποτελεσματικά μοντέλα ML που μπορούν να βοηθήσουν στη λήψη αποφάσεων σε πραγματικό χρόνο. Αυτά τα μοντέλα μπορούν να εκπαιδευτούν να ακολουθούν συγκεκριμένα μονοπάτια αποφάσεων με βάση τα δεδομένα εισόδου, καθιστώντας τα κατάλληλα για την εφαρμογή κλινικών οδηγιών και πρωτοκόλλων. Στην IONM, τα δέντρα αποφάσεων μπορούν να βοηθήσουν στην τυποποίηση των αντιδράσεων σε κοινά νευρικά γεγονότα, εξασφαλίζοντας συνεπείς και βάσει αποδείξεων ενέργειες κατά τη διάρκεια της χειρουργικής επέμβασης.

- **Βελτίωση της Αποδοτικότητας Εργασιών:** Η ενσωμάτωση της ML στην IONM μπορεί επίσης να βελτιώσει την αποδοτικότητα των εργασιών αυτοματοποιώντας ρουτίνες εργασίες και απλοποιώντας τη διαδικασία παρακολούθησης. Αυτή η αποδοτικότητα μπορεί να οδηγήσει σε καλύτερη αξιοποίηση των πόρων και μειωμένο γνωστικό φορτίο στους επαγγελματίες υγείας.
- **Αυτοματοποιημένη Επεξεργασία Δεδομένων:** Οι αλγόριθμοι ML μπορούν να αυτοματοποιήσουν την επεξεργασία μεγάλων όγκων νευροφυσιολογικών δεδομένων που παράγονται κατά τη διάρκεια της χειρουργικής επέμβασης. Εργασίες όπως ο καθαρισμός δεδομένων, η κανονικοποίηση και η αφαίρεση των artifact μπορούν να διεκπεραιωθούν από τα μοντέλα ML, απελευθερώνοντας τους νευροφυσιολόγους για να επικεντρωθούν σε υψηλότερου επιπέδου ανάλυση και λήψη αποφάσεων. Η αυτοματοποιημένη επεξεργασία δεδομένων διασφαλίζει ότι τα δεδομένα παρακολούθησης είναι σταθερά προετοιμασμένα και έτοιμα για ανάλυση, μειώνοντας τις καθυστερήσεις και πιθανά λάθη.
- **Εξατομικευμένα Πρωτόκολλα Παρακολούθησης:** Η ML μπορεί να επιτρέψει την ανάπτυξη εξατομικευμένων πρωτοκόλλων παρακολούθησης προσαρμοσμένων σε μεμονωμένους ασθενείς. Αναλύοντας δεδομένα συγκεκριμένων ασθενών, όπως ιατρικό ιστορικό, βασική νευρική δραστηριότητα και ενδοεγχειρητικές συνθήκες, τα μοντέλα ML μπορούν να προτείνουν εξατομικευμένες στρατηγικές παρακολούθησης που βελτιστοποιούν την ευαισθησία και την εξειδίκευση της IONM. Τα εξατομικευμένα πρωτόκολλα μπορούν να βελτιώσουν την ακρίβεια των νευρικών αξιολογήσεων και να ενισχύσουν τα αποτελέσματα των ασθενών.
- **Βελτιστοποίηση Πόρων:** Η βελτιστοποίηση πόρων περιλαμβάνει τη χρήση ML για την κατανομή των πόρων παρακολούθησης πιο αποτελεσματικά. Για παράδειγμα, τα μοντέλα ML μπορούν να προβλέψουν την πιθανότητα νευρικών γεγονότων με βάση τα προεγχειρητικά και ενδοεγχειρητικά δεδομένα, επιτρέποντας τη στρατηγική ανάπτυξη νευροφυσιολόγων και εξοπλισμού παρακολούθησης. Αυτή η προσέγγιση διασφαλίζει ότι οι ασθενείς υψηλού κινδύνου λαμβάνουν την πιο εντατική παρακολούθηση, ενώ οι περιπτώσεις χαμηλού κινδύνου διαχειρίζονται αποτελεσματικά, βελτιστοποιώντας τη χρήση των διαθέσιμων πόρων (16).

#### 1.3.4 Προκλήσεις και Μελλοντικές Κατευθύνσεις

Παρόλο που η εφαρμογή της ML στην IONM έχει μεγάλες προοπτικές, υπάρχουν πολλές προκλήσεις που πρέπει να αντιμετωπιστούν για να αξιοποιηθεί πλήρως το δυναμικό της.

- **Ποιότητα και Ποσότητα Δεδομένων:** Τα μοντέλα ML απαιτούν μεγάλα ποσά υψηλής ποιότητας δεδομένων για την εκπαίδευση και την επικύρωση. Στο πλαίσιο της IONM, η απόκτηση ολοκληρωμένων συνόλων δεδομένων μπορεί να αποτελέσει πρόκληση λόγω της ποικιλομορφίας στις χειρουργικές διαδικασίες και τις συνθήκες των ασθενών. Προσπάθειες για την τυποποίηση των πρωτοκόλλων συλλογής δεδομένων και τη δημιουργία κοινών βάσεων δεδομένων μπορούν να βοηθήσουν στην υπέρβαση αυτής της πρόκλησης.
- **Ερμηνευσιμότητα Μοντέλων:** Η ερμηνευσιμότητα των μοντέλων ML, ιδιαίτερα των μοντέλων βαθιάς μάθησης, αποτελεί κρίσιμο ζήτημα σε κλινικά περιβάλλοντα. Οι επαγγελματίες υγείας πρέπει να κατανοούν πώς τα μοντέλα ML καταλήγουν στις προβλέψεις τους για να τα εμπιστεύονται και να τα χρησιμοποιούν αποτελεσματικά.

Η έρευνα στην ερμηνεύσιμη AI (XAI) στοχεύει στην ανάπτυξη μεθόδων για την καθιστώντας τα μοντέλα ML πιο διαφανή και ερμηνεύσιμα.


- **Ενσωμάτωση στη Κλινική Ροή Εργασίας:** Η ενσωμάτωση της ML στις υπάρχουσες κλινικές ροές εργασίας απαιτεί προσεκτικό σχεδιασμό και συνεργασία μεταξύ κλινικών ιατρών, νευροφυσιολόγων και επιστημόνων δεδομένων. Οι φιλικές προς τον χρήστη διεπαφές και η απρόσκοπτη ενσωμάτωση με τα συστήματα IONM είναι ουσιαστικά για να εξασφαλιστεί ότι τα εργαλεία ML υιοθετούνται και χρησιμοποιούνται ευρέως στην πράξη.
- **Ηθικές και Κανονιστικές Σκέψεις:** Η χρήση της ML στην υγεία εγείρει ηθικές και κανονιστικές σκέψεις, όπως η προστασία των δεδομένων και οι πιθανές ανεπιθύμητες συνέπειες. Η διασφάλιση ότι τα μοντέλα ML αναπτύσσονται και εφαρμόζονται υπεύθυνα, με κατάλληλες διασφαλίσεις και εποπτεία, είναι κρίσιμη για την επιτυχή υλοποίησή τους.
- **Μελλοντικές Κατευθύνσεις:** Η μελλοντική έρευνα στην ML για την IONM πιθανότατα θα επικεντρωθεί στην ανάπτυξη πιο εξελιγμένων μοντέλων που μπορούν να διαχειριστούν την πολυπλοκότητα και τη μεταβλητότητα των νευροφυσιολογικών δεδομένων. Οι εξελίξεις στην ενισχυτική μάθηση, τη μεταφορά μάθησης και την ομόσπονδη μάθηση έχουν τη δυνατότητα να βελτιώσουν την απόδοση και τη γενικευσιμότητα των μοντέλων. Επιπλέον, οι διεπιστημονικές συνεργασίες και οι κλινικές δοκιμές θα είναι ουσιαστικές για την επικύρωση και τη βελτίωση των εφαρμογών ML στην IONM, ενισχύοντας τελικά την ασφάλεια των ασθενών και τα χειρουργικά αποτελέσματα

## 1.4 Ανάλυση μεθόδων ενδοεγχειρητικής νευροπαρακολούθησης

### 1.4.1 Ανάλυση των Σωματοαισθητικών Προκλητών Δυναμικών (SSEPs)

#### *Αρχή και Εφαρμογή*

Τα Σωματοαισθητικά Προκλητά Δυναμικά (SSEPs) είναι ηλεκτροφυσιολογικές αντιδράσεις που δημιουργούνται από το κεντρικό νευρικό σύστημα ως απάντηση σε διέγερση περιφερικών νεύρων. Καταγράφονται από το κρανίο ή του νωτιαίου μυελού μετά από ηλεκτρική διέγερση ενός περιφερικού νεύρου, συνήθως του μέσου ή του οπίσθιου κνημιαίου νεύρου. Τα SSEPs παρέχουν πολύτιμες πληροφορίες για την λειτουργική ακεραιότητα των αισθητηριακών οδών, από τα περιφερικά νεύρα μέσω του νωτιαίου μυελού έως τον αισθητηριακό φλοιό. Τα SSEPs χρησιμοποιούνται ευρέως σε διάφορες νευροχειρουργικές και ορθοπεδικές επεμβάσεις για την παρακολούθηση της λειτουργικής κατάστασης των σωματοαισθητήριων οδών. Είναι ιδιαίτερα χρήσιμα σε χειρουργικές επεμβάσεις που διατρέχουν κίνδυνο για τον νωτιαίο μυελό ή τον εγκέφαλο, επιτρέποντας την άμεση αξιολόγηση της νευρικής λειτουργίας και την άμεση παρέμβαση εάν ανιχνευθεί νευρική βλάβη.



Εικόνα 1.8: Σήματα ssep(17)

Τα SSEPs χρησιμοποιούνται συστηματικά στις επεμβάσεις σπονδυλικής στήλης για την παρακολούθηση των οπισθίων στηλών του νωτιαίου μυελού, οι οποίες μεταφέρουν αισθητηριακές πληροφορίες. Βοηθούν στην ανίχνευση ισχαιμίας ή μηχανικής βλάβης του νωτιαίου μυελού κατά τη διάρκεια επεμβάσεων όπως αποσυμπίεση σπονδυλικής στήλης, σπονδυλοδεσία και διόρθωση σκολίωσης. Η χρήση των SSEPs στις επεμβάσεις σπονδυλικής στήλης έχει δείξει μείωση της επίπτωσης μετεγχειρητικών νευρολογικών ελλειμμάτων, επιτρέποντας άμεσες διορθωτικές ενέργειες όταν ανιχνεύονται αλλαγές στα σήματα SSEPs.

Στις επεμβάσεις εγκεφάλου, τα SSEPs χρησιμοποιούνται για την παρακολούθηση της ακεραιότητας των αισθητηριακών οδών και την εξασφάλιση ότι η χειρουργική επέμβαση δεν προκαλεί βλάβη στην αισθητηριακή λειτουργία. Είναι ιδιαίτερα χρήσιμα σε επεμβάσεις που περιλαμβάνουν τον αισθητηριακό φλοιό ή περιοχές κοντά σε αυτόν. Τα SSEPs παρέχουν συνεχή ανατροφοδότηση για την λειτουργική κατάσταση των αισθητηριακών οδών, βοηθώντας τους χειρουργούς να αποφύγουν τη βλάβη σε κρίσιμες νευρικές δομές.

Σε ορθοπεδικές επεμβάσεις, όπως αντικαταστάσεις ισχίου και γόνατος, τα SSEPs μπορούν να χρησιμοποιηθούν για την παρακολούθηση της των αισθητηριακών οδών που μπορεί να βρίσκονται σε κίνδυνο κατά τη διάρκεια της επέμβασης. Η χρήση των SSEPs στις ορθοπεδικές επεμβάσεις μπορεί να βοηθήσει στην έγκαιρη ανίχνευση πιθανών νευρικών βλαβών, επιτρέποντας έγκαιρη παρέμβαση για την αποτροπή μόνιμης ζημιάς.

### Πλεονεκτήματα

1. **Μη Επεμβατική Μέθοδος:** Τα SSEPs είναι μια μη επεμβατική τεχνική παρακολούθησης που δεν απαιτεί άμεση πρόσβαση στις νευρικές δομές.
2. **Άμεση Ανατροφοδότηση:** Παρέχουν συνεχή άμεση ανατροφοδότηση για την λειτουργική κατάσταση των σωματ αισθητήριων οδών, επιτρέποντας άμεσες διορθωτικές ενέργειες αν ανιχνευθεί νευρική βλάβη.
3. **Ευελιξία:** Τα SSEPs μπορούν να χρησιμοποιηθούν σε ένα ευρύ φάσμα χειρουργικών επεμβάσεων, από επεμβάσεις στη σπονδυλική στήλη έως εγκεφαλικές και ορθοπεδικές επεμβάσεις, παρέχοντας πολύτιμες πληροφορίες για την ακεραιότητα των αισθητηριακών οδών.

### Περιορισμοί

1. **Επιρροή Αναισθησίας:** Η αξιοπιστία των σημάτων SSEPs μπορεί να επηρεαστεί από αναισθητικά φάρμακα, ιδιαίτερα εκείνα που καταστέλλουν τη δραστηριότητα του κεντρικού νευρικού συστήματος. Είναι σημαντικό να επιλέγονται αναισθητικά πρωτόκολλα που ελαχιστοποιούν αυτές τις επιδράσεις.
2. **Απαιτούμενη Εμπειρογνωμοσύνη:** Η ακριβής ερμηνεία των σημάτων SSEPs απαιτεί σημαντική εμπειρογνωμοσύνη και εμπειρία. Οι νευροφυσιολόγοι και οι χειρουργικές ομάδες πρέπει να είναι καλά εκπαιδευμένοι στην αναγνώριση και αντίδραση σε αλλαγές στα πρότυπα SSEPs.
3. **Ψευδώς Θετικά/Αρνητικά:** Υπάρχει η πιθανότητα ψευδώς θετικών ή αρνητικών αποτελεσμάτων, που μπορούν να οδηγήσουν σε περιττές παρεμβάσεις ή σε χαμένες ευκαιρίες για διορθωτικές ενέργειες. Η ευαισθησία και η ειδικότητα των SSEPs δεν είναι απόλυτες και θα πρέπει να χρησιμοποιούνται σε συνδυασμό με άλλες μεθόδους παρακολούθησης για συνολική αξιολόγηση.

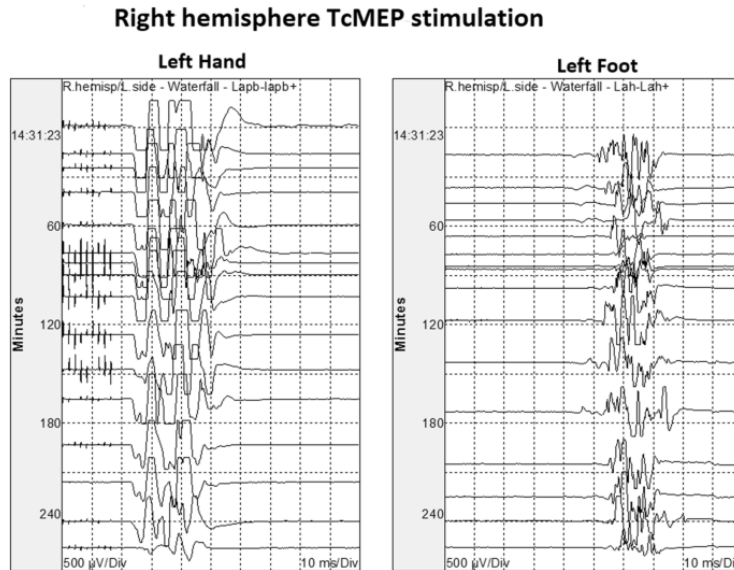
### Τεχνικά Θέματα

1. **Τοποθέτηση Ηλεκτροδίων:** Η σωστή τοποθέτηση των ηλεκτροδίων διέγερσης, ώστε να εντοπιστεί με ακρίβεια για παράδειγμα το μέσο νεύρο και καταγραφής είναι κρίσιμη για την απόκτηση ακριβών και αξιόπιστων σημάτων SSEPs. Η κακή τοποθέτηση μπορεί να οδηγήσει σε χαμηλή ποιότητα σήματος ή εσφαλμένη ερμηνεία των αποτελεσμάτων.
2. **Παράμετροι Διέγερσης:** Η ένταση, η διάρκεια και η συχνότητα της ηλεκτρικής διέγερσης πρέπει να ελέγχονται προσεκτικά για να επιτευχθούν συνεπή και αναπαραγώγιμα σήματα SSEPs χωρίς να προκαλείται δυσφορία ή βλάβη στον ασθενή.
3. **Άθροισμα Σημάτων:** Τα SSEPs είναι συνήθως χαμηλής έντασης και μπορεί να καλυφθούν από περιβαλλοντικό θόρυβο. Οι τεχνικές αθροισμού σημάτων χρησιμοποιούνται για την ενίσχυση του λόγου σήματος προς θόρυβο, επιτρέποντας καθαρότερη ερμηνεία των προκαλούμενων αντιδράσεων.

#### 1.4.2 Ανάλυση των Προκλητών Δυναμικών Κινητικών (MEPs)

Τα Προκλητά Δυναμικά Κινητήρων (MEPs) είναι ηλεκτρικές αντιδράσεις που δημιουργούνται στους μυς μετά από άμεση ή διακρανιακή ηλεκτρική διέγερση του κινητικού φλοιού. Αξιολογούν την λειτουργική ακεραιότητα κινητικών οδών καταγράφοντας την επακόλουθη μυϊκή δραστηριότητα.

Τα MEPs χρησιμοποιούνται εκτενώς κατά τη διάρκεια επεμβάσεων που διατρέχουν κίνδυνο για κινητικές οδούς, όπως επεμβάσεις σπονδυλικής στήλης και εγκεφάλου. Η άμεση ανατροφοδότησή τους επιτρέπει άμεση παρέμβαση για την αποτροπή μόνιμων κινητικών ελλειμμάτων.



**Εικόνα 1.9: σήματα mep(18)**

Τα MEPs είναι κρίσιμα σε χειρουργικές επεμβάσεις σπονδυλικής στήλης, ιδιαίτερα εκείνες που αφορούν τις αυχενικές και θωρακικές περιοχές, για την παρακολούθηση των κινητικών οδών. Η χρήση των MEPs σε αυτές τις επεμβάσεις βοηθά στην έγκαιρη ανίχνευση πιθανής βλάβης στις κινητικές οδούς, επιτρέποντας στους χειρουργούς να κάνουν τις απαραίτητες προσαρμογές για να αποφύγουν μόνιμη ζημιά.

Τα MEPs χρησιμοποιούνται σε εγκεφαλικές επεμβάσεις, ιδιαίτερα εκείνες που αφορούν περιοχές του κινητικού φλοιού, για να διασφαλιστεί ότι ο χειρουργικός χειρισμός δεν θα επηρεάσει την κινητική λειτουργία. Η συνεχής παρακολούθηση των MEPs βοηθά στη διατήρηση της κινητικής λειτουργίας, παρέχοντας άμεσες πληροφορίες για την κατάσταση των κινητικών οδών κατά την αφαίρεση όγκων του εγκεφάλου ή σε επεμβάσεις επιληψίας.

### **Πλεονεκτήματα**

1. **Άμεση Παρακολούθηση Κινητικών Οδών:** Τα MEPs παρέχουν άμεση αξιολόγηση της λειτουργικής ακεραιότητας των κινητικών οδών, προσφέροντας άμεσες πληροφορίες για την κατάσταση της πυραμδικής οδού. Τα MEPs μπορούν να ανιχνεύσουν αλλαγές στην ακεραιότητα των κινητικών οδών σχεδόν αμέσως, επιτρέποντας γρήγορες χειρουργικές προσαρμογές για την αποφυγή μόνιμης ζημιάς.
2. **Υψηλή Ευαισθησία:** Τα MEPs είναι ιδιαίτερα ευαίσθητα σε αλλαγές στην κινητική λειτουργία, καθιστώντας τα αξιόπιστο εργαλείο παρακολούθησης κατά τη διάρκεια χειρουργικών επεμβάσεων υψηλού κινδύνου.

### **Περιορισμοί**

1. **Ευαισθησία στην Αναισθησία:** Οι αντιδράσεις των MEP είναι ιδιαίτερα ευαίσθητες σε αναισθητικά φάρμακα, ιδιαίτερα εκείνα που καταστέλλουν τη δραστηριότητα του κεντρικού νευρικού συστήματος. Αυτό απαιτεί προσεκτική επιλογή και διαχείριση της αναισθησίας για να εξασφαλιστεί η αξιόπιστη παρακολούθηση των MEP.


2. **Σύνθετη Διαμόρφωση:** Η διαμόρφωση για την παρακολούθηση των MEP είναι πιο σύνθετη σε σύγκριση με άλλες μεθόδους IONM. Απαιτεί ακριβή τοποθέτηση των ηλεκτροδίων διέγερσης και καταγραφής και προσεκτικό έλεγχο των παραμέτρων διέγερσης.
3. **Παρεμβολές:** Τα σήματα MEP μπορεί να επηρεαστούν από διάφορους παράγοντες, συμπεριλαμβανομένης της κίνησης του ασθενούς, ηλεκτρικών παρεμβολών από χειρουργικό εξοπλισμό και φυσιολογικής μεταβλητότητας. Αυτό απαιτεί εξειδίκευση στην ερμηνεία των σημάτων για την αποφυγή ψευδώς θετικών ή αρνητικών αποτελεσμάτων.

### Τεχνικές Σκέψεις

1. **Τοποθέτηση Ηλεκτροδίων:** Η ακριβής τοποθέτηση των ηλεκτροδίων στο κρανίο και τους μυς είναι κρίσιμη για την απόκτηση αξιόπιστων σημάτων MEP. Η κακή τοποθέτηση μπορεί να οδηγήσει σε χαμηλή ποιότητα σήματος ή εσφαλμένη ερμηνεία.
2. **Παράμετροι Διέγερσης:** Η ένταση, η διάρκεια και η συχνότητα της ηλεκτρικής διέγερσης πρέπει να ελέγχονται προσεκτικά για να επιτευχθούν συνεπή και αναπαραγώγιμα σήματα MEP χωρίς να προκαλείται δυσφορία ή βλάβη στον ασθενή.
3. **Αθροισμός Σημάτων:** Δεδομένου του πιθανού περιβαλλοντικού θορύβου, χρησιμοποιούνται τεχνικές αθροισμού σημάτων για την ενίσχυση του λόγου σήματος προς θόρυβο, εξασφαλίζοντας καθαρότερη ερμηνεία των αντιδράσεων MEP(12).

### 1.4.3 Ανάλυση της Ηλεκτρομυογραφίας (EMG)

Το Ηλεκτρομυογράφημα (EMG) μετρά την ηλεκτρική δραστηριότητα που παράγεται από τους σκελετικούς μύες. Περιλαμβάνει την εισαγωγή λεπτών βελόνων ή ηλεκτροδίων στον μυϊκό ιστό για την ανίχνευση ηλεκτρικών δυναμικών που δημιουργούνται από τις μυϊκές ίνες όταν συσπώνται. Το EMG μπορεί να είναι είτε αυθόρμητο είτε προκλητό. Η αυθόρμητο EMG ανιχνεύει τη συνεχή μυϊκή δραστηριότητα, ενώ το προκλητό EMG περιλαμβάνει τη διέγερση ενός νεύρου και την καταγραφή της επακόλουθης μυϊκής αντίδρασης.



Εικόνα 1.10: σήμα emg(19)

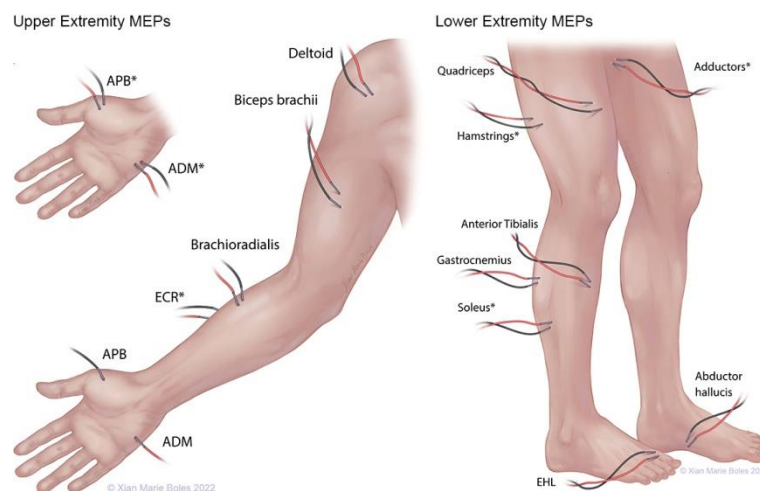


Το EMG χρησιμοποιείται ευρέως κατά τη διάρκεια επεμβάσεων που αφορούν περιφερικά νεύρα, νωτιαίο μυελό και εγκέφαλο για την παρακολούθηση της ακεραιότητας των κινητικών οδών και την εξασφάλιση ότι τα νεύρα δεν καταστρέφονται κατά τη διάρκεια της διαδικασίας. Παρέχει άμεση ανατροφοδότηση για την κατάσταση των νευρικών δομών, επιτρέποντας άμεσες χειρουργικές προσαρμογές εάν είναι απαραίτητο.

Το EMG χρησιμοποιείται εκτενώς σε χειρουργικές επεμβάσεις περιφερικών νεύρων για την αναγνώριση και διατήρηση των κινητικών νεύρων. Βοηθά στον εντοπισμό της πορείας των νεύρων, εξασφαλίζοντας ότι δεν θα καταστραφούν ακούσια κατά τη διάρκεια της ανατομής. Η άμεση ανατροφοδότηση του EMG μπορεί να αποτρέψει την τραυματισμό των νεύρων καθοδηγώντας τον χειρουργό στην αποφυγή ή την ελάχιστη μεταχείριση των κρίσιμων νεύρων. Αυτό μπορεί να είναι κρίσιμο σε χειρουργικές επεμβάσεις που περιλαμβάνουν το βραχιόνιο πλέγμα, το προσωπικό νεύρο ή άλλα μεγάλα περιφερικά νεύρα.

Το EMG χρησιμοποιείται στις επεμβάσεις σπονδυλικής στήλης για την παρακολούθηση της λειτουργίας των νευρικών ριζών. Αυτό είναι ιδιαίτερα σημαντικό κατά τη διάρκεια επεμβάσεων όπως αποσυμπίεση σπονδυλικής στήλης, σπονδυλοδεσία ή τοποθέτηση εμφυτευμάτων, όπου οι νευρικές ρίζες μπορεί να βρίσκονται σε κίνδυνο. Η χρήση του EMG στις επεμβάσεις σπονδυλικής στήλης βοηθά στην ανίχνευση ερεθισμού ή βλάβης των νεύρων νωρίς, επιτρέποντας άμεσες διορθωτικές ενέργειες. Αυτό μειώνει τον κίνδυνο μετεγχειρητικών νευρολογικών ελλειμμάτων όπως αδυναμία ή μουδιάσματα.

Κατά τη διάρκεια εγκεφαλικών επεμβάσεων, η EMG μπορεί να χρησιμοποιηθεί για την παρακολούθηση των κρανιακών νεύρων, ειδικά αυτών που εμπλέκονται στις κινήσεις του προσώπου, τις κινήσεις των ματιών και την κατάποση. Η παρακολούθηση του emg κατά τη διάρκεια εγκεφαλικών επεμβάσεων βοηθά στη διατήρηση της λειτουργίας των κρανιακών νεύρων παρέχοντας άμεσες πληροφορίες για την ακεραιότητα των νεύρων. Αυτό είναι ιδιαίτερα χρήσιμο σε επεμβάσεις για ακουστικά νευρινώματα, όγκους βάσης του κρανίου και άλλες κρανιακές διαδικασίες.



Εικόνα 1.11: Τοποθεσία mep/emg(20)

## Πλεονεκτήματα


1. **Άμεση Παρακολούθηση:** το EMG παρέχει άμεση ανατροφοδότηση για τη λειτουργία των μυών και των νευρών, επιτρέποντας άμεση παρέμβαση αν ανιχνευθεί νευρική βλάβη.
2. **Υψηλή Ευαισθησία:** το EMG είναι ιδιαίτερα ευαίσθητη στον ερεθισμό και την βλάβη των νευρών, καθιστώντας την αποτελεσματικό εργαλείο για την αποτροπή νευρικών επιπλοκών κατά τη διάρκεια χειρουργικής επέμβασης.
3. **Ευελιξία:** το EMG μπορεί να χρησιμοποιηθεί σε ποικιλία χειρουργικών επεμβάσεων που αφορούν περιφερικά νεύρα, σπονδυλική στήλη και εγκέφαλο, παρέχοντας πολύτιμες πληροφορίες για τη λειτουργική κατάσταση των κινητικών οδών.

### Περιορισμοί

1. **Επεμβατικότητα:** Η εισαγωγή βελόνων ή ηλεκτροδίων στον μυϊκό ιστό μπορεί να προκαλέσει δυσφορία και ίσως να μην είναι κατάλληλη για όλους τους ασθενείς.
2. **Παρεμβολές:** Τα σήματα του emg μπορεί να επηρεαστούν από εξωτερικούς παράγοντες όπως η κίνηση του ασθενούς, ηλεκτρικές παρεμβολές από χειρουργικό εξοπλισμό και φυσιολογική μεταβλητότητα. Αυτό απαιτεί εξειδίκευση στην ερμηνεία των σημάτων για την αποφυγή ψευδώς θετικών ή αρνητικών αποτελεσμάτων.
3. **Απαίτηση Ειδικότητας:** Η ακριβής ερμηνεία των σημάτων του emg απαιτεί σημαντική εξειδίκευση. Οι χειρουργοί και οι νευροφυσιολόγοι πρέπει να είναι καλά εκπαιδευμένοι στην αναγνώριση και αντίδραση στις αλλαγές των προτύπων του emg.

### 1.4.4 Ανάλυση των Προκλητών Δυναμικών του Εγκεφαλικού Στελέχους (BAEPs)

Τα Προκλητά Δυναμικά του Εγκεφαλικού Στελέχους (BAEPs), επίσης γνωστά ως Ακουστικά Προκλητά Δυναμικά του Εγκεφαλικού Στελέχους (BAERs), είναι ηλεκτροφυσιολογικές αντιδράσεις από το εγκεφαλικό στέλεχος μετά από ακουστικά ερεθίσματα, συνήθως κλικ ή ηχητικούς παλμούς. Αυτές οι αντιδράσεις μετρώνται τοποθετώντας ηλεκτρόδια στο κρανίο και καταγράφοντας την ηλεκτρική δραστηριότητα που παράγεται από τις ακουστικές οδούς καθώς ο ήχος ταξιδεύει από το αυτί μέσω του ακουστικού νεύρου στο εγκεφαλικό στέλεχος.



Εικόνα 1.12: baep σήματα(21)

Τα ΒΑΕΡs χρησιμοποιούνται για την παρακολούθηση της ακεραιότητας των ακουστικών οδών και της λειτουργίας του εγκεφαλικού στελέχους κατά τη διάρκεια επεμβάσεων που διατρέχουν κίνδυνο για αυτές τις δομές. Είναι ιδιαίτερα χρήσιμα σε επεμβάσεις που περιλαμβάνουν τον οπίσθιο βόθρο, ακουστικά νευρινώματα και άλλες διαδικασίες όπου το ακουστικό νεύρο ή το εγκεφαλικό στέλεχος μπορεί να βρίσκονται σε κίνδυνο.

ΒΑΕΡ χρησιμοποιούνται εκτενώς κατά τη διάρκεια χειρουργικών επεμβάσεων ακουστικού νευρινώματος για την παρακολούθηση του ακουστικού νεύρου. Η χρήση των ΒΑΕΡ σε αυτές τις χειρουργικές επεμβάσεις συμβάλλει στη διατήρηση της ακοής παρέχοντας ανατροφοδότηση σε πραγματικό χρόνο σχετικά με τη λειτουργική κατάσταση του ακουστικού νεύρου, επιτρέποντας στους χειρουργούς να προσαρμόζουν τις τεχνικές τους για την αποφυγή βλάβης του νεύρου (22).

Σε χειρουργικές επεμβάσεις που αφορούν το εγκεφαλικό στέλεχος, τα ΒΑΕΡ είναι ζωτικής σημασίας για την παρακολούθηση της λειτουργίας του εγκεφαλικού στελέχους και την ανίχνευση κάθε ενδεχόμενου συμβιβασμού σε πρώιμο στάδιο της διαδικασίας. συνεχής παρακολούθηση του ΒΑΕΡ παρέχει άμεσες πληροφορίες σχετικά με την ακεραιότητα του εγκεφαλικού στελέχους, βοηθώντας στην αποφυγή μετεγχειρητικών νευρολογικών ελλειμμάτων, όπως η απώλεια ακοής ή άλλα ελλείμματα κρανιακών νεύρων .

Τα ΒΑΕΡ χρησιμοποιούνται κατά τη διάρκεια της αφαίρεσης όγκων στην παρεγκεφαλίδα για την παρακολούθηση των ακουστικών οδών και του εγκεφαλικού στελέχους. Τα ΒΑΕΡ βοηθούν στην ελαχιστοποίηση του κινδύνου βλάβης του ακουστικού νεύρου και των δομών του εγκεφαλικού στελέχους, διατηρώντας έτσι την ακοή και προλαμβάνοντας άλλες επιπλοκές (23) .

### **Πλεονεκτήματα**

1.Μη επεμβατικά: Τα ΒΑΕΡ είναι μια μη επεμβατική τεχνική παρακολούθησης που δεν απαιτεί άμεση πρόσβαση στις νευρικές δομές.

2.Συνεχής παρακολούθηση: Παρέχουν συνεχή ανατροφοδότηση σε πραγματικό χρόνο σχετικά με τη λειτουργική κατάσταση των ακουστικών οδών και του εγκεφαλικού στελέχους.

### **Περιορισμοί**

- **Περιορισμένη εμβέλεια:** Τα ΒΑΕΡ παρακολουθούν ειδικά τις ακουστικές οδούς και το εγκεφαλικό στέλεχος, προσφέροντας περιορισμένες πληροφορίες για άλλες νευρικές δομές.
- **Ευαισθησία σε εξωτερικούς παράγοντες:** Τα σήματα ΒΑΕΡ μπορούν να επηρεαστούν από παράγοντες όπως ο θόρυβος του περιβάλλοντος, η κίνηση του ασθενούς και η τοποθέτηση των ηλεκτροδίων, απαιτώντας προσεκτικό έλεγχο και εξειδίκευση στην ερμηνεία του σήματος.
- **Εξειδικευμένος εξοπλισμός και εμπειρογνωμοσύνη:** Η ακριβής ερμηνεία των σημάτων ΒΑΕΡ απαιτεί εξειδικευμένο εξοπλισμό και σημαντική εμπειρογνωμοσύνη, η οποία ενδέχεται να μην είναι διαθέσιμη σε όλες τις χειρουργικές εγκαταστάσεις.

#### 1.4.5 Ανάλυση των οπτικά προκλητών δυναμικών (VEP)

Τα οπτικά προκλητά δυναμικά (VEPs) είναι ηλεκτρικά δυναμικά που ξεκινούν από σύντομα οπτικά ερεθίσματα και καταγράφονται από το τριχωτό της κεφαλής που βρίσκεται πάνω από τον ινιακό φλοιό. Αξιολογούν τη λειτουργική ακεραιότητα των οπτικών οδών από τα μάτια στον οπτικό φλοιό του εγκεφάλου. Τα VEPs παράγονται με την παρουσίαση ενός οπτικού ερεθίσματος, όπως ένα φως που αναβοσβήνει ή ένα μοτίβο σε μια οθόνη, και την καταγραφή της ηλεκτρικής απόκρισης του εγκεφάλου. Τα VEP χρησιμοποιούνται κατά τη διάρκεια χειρουργικών επεμβάσεων που ενέχουν κίνδυνο για τις οπτικές οδούς, ιδίως εκείνων που αφορούν τα οπτικά νεύρα, το οπτικό χίασμα και τον ινιακό φλοιό. Βοηθούν στην παρακολούθηση της ακεραιότητας των οπτικών οδών, επιτρέποντας άμεσες χειρουργικές προσαρμογές για την πρόληψη οπτικών ελλειμμάτων.

Οι VEP είναι κρίσιμες κατά τη διάρκεια χειρουργικών επεμβάσεων που αφορούν το οπτικό νεύρο, όπως οι επεμβάσεις εκτομής όγκου ή αποσυμπίεσης. Η παρακολούθηση των VEPs συμβάλλει στη διατήρηση της οπτικής λειτουργίας παρέχοντας ανατροφοδότηση σε πραγματικό χρόνο σχετικά με την ακεραιότητα του οπτικού νεύρου και των οπτικών οδών, επιτρέποντας στους χειρουργούς να ελαχιστοποιήσουν τη βλάβη .

Τα VEPs χρησιμοποιούνται σε χειρουργικές επεμβάσεις εγκεφάλου, ιδίως σε αυτές που αφορούν τον ινιακό λοβό, για την παρακολούθηση της ακεραιότητας των οπτικών οδών. Το οπτικό σύστημα μπορεί να χρησιμοποιηθεί για την παρακολούθηση της βλεπόμενης περιοχής: Η συνεχής παρακολούθηση του VEP κατά τη διάρκεια της χειρουργικής επέμβασης στον εγκέφαλο βοηθά στην αποφυγή βλάβης του οπτικού φλοιού, διατηρώντας έτσι την οπτική λειτουργία μετεγχειρητικά .

Τα VEP μπορούν να χρησιμοποιηθούν κατά τη διάρκεια χειρουργικών επεμβάσεων για ενδοκρανιακά ανευρύσματα, ιδίως αυτά που βρίσκονται κοντά στις οπτικές οδούς. Παρέχουν ανατροφοδότηση σε πραγματικό χρόνο σχετικά με τη λειτουργική κατάσταση των οπτικών οδών, επιτρέποντας άμεσες διορθωτικές ενέργειες εάν εντοπιστούν αλλαγές στα σήματα VEP

#### **Πλεονεκτήματα**

- **Μη επεμβατικό:** Οι VEP είναι μια μη επεμβατική τεχνική παρακολούθησης, η οποία παρέχει αξιολόγηση της λειτουργίας των οπτικών οδών σε πραγματικό χρόνο χωρίς να απαιτείται άμεση πρόσβαση στις νευρικές δομές.
- **Άμεση ανατροφοδότηση:** Προσφέρουν άμεση ανατροφοδότηση σχετικά με την ακεραιότητα των οπτικών οδών, επιτρέποντας γρήγορες χειρουργικές προσαρμογές για την πρόληψη μόνιμων οπτικών ελλειμμάτων.
- **Αξιόπιστη παρακολούθηση:** Τα VEP παρέχουν αξιόπιστη παρακολούθηση των οπτικών οδών, γεγονός που τα καθιστά πολύτιμα σε χειρουργικές επεμβάσεις όπου η οπτική λειτουργία κινδυνεύει.

#### **Περιορισμοί**

- **Ευαισθησία σε εξωτερικούς παράγοντες:** Τα σήματα VEP μπορούν να επηρεαστούν από εξωτερικούς παράγοντες, όπως οι συνθήκες φωτισμού του περιβάλλοντος, η συνεργασία του ασθενούς και η τοποθέτηση των ηλεκτροδίων, απαιτώντας προσεκτικό έλεγχο και εμπειρογνωμοσύνη στην ερμηνεία του σήματος.

- **Περιορισμένες πληροφορίες:** Τα VEP παρακολουθούν ειδικά τις οπτικές οδούς και ενδέχεται να μην παρέχουν ολοκληρωμένες πληροφορίες για άλλες νευρικές δομές.
- **Παρεμβολές:** Τα σήματα VEP μπορούν να επηρεαστούν από ηλεκτρικές παρεμβολές από χειρουργικό εξοπλισμό, γεγονός που καθιστά αναγκαία την εφαρμογή ισχυρών τεχνικών φιλτραρίσματος και επεξεργασίας σήματος για να διασφαλιστεί η ακριβής ερμηνεία.

#### **Τεχνικές θέματα**

- **Τοποθέτηση ηλεκτροδίων:** Η ακριβής τοποθέτηση των ηλεκτροδίων στο τριχωτό της κεφαλής είναι ζωτικής σημασίας για τη λήψη αξιόπιστων σημάτων VEP. Η λανθασμένη τοποθέτηση μπορεί να οδηγήσει σε κακή ποιότητα σήματος ή λανθασμένη ερμηνεία.
- **Παράμετροι διέγερσης:** Τα χαρακτηριστικά του οπτικού ερεθίσματος (π.χ. ένταση, συχνότητα και μοτίβο) πρέπει να ελέγχονται προσεκτικά για την πρόκληση συνεπών και αναπαραγώγιμων αποκρίσεων VEP.
- **Μέτρηση σήματος:** Τα VEP είναι συνήθως μικρού πλάτους και μπορούν να καλυφθούν από θόρυβο υποβάθρου. Οι τεχνικές υπολογισμού του μέσου όρου του σήματος χρησιμοποιούνται για τη βελτίωση του λόγου σήματος προς θόρυβο, εξασφαλίζοντας σαφέστερη ερμηνεία των προκλητών αποκρίσεων (24).

#### **1.4.6 Ανάλυση δέλτα κύμα (D wave)**

Το D-Wave είναι ένας τύπος προκλητού δυναμικού που αντανακλά άμεσα την αγωγή των δυναμικών δράσης μέσω της φλοιώδους-σπονδυλικής οδού, η οποία είναι ζωτικής σημασίας για την κινητική λειτουργία. Σε αντίθεση με άλλα προκλητά δυναμικά που αντανακλούν έμμεση νευρική δραστηριότητα, το D-Wave καταγράφεται από τον νωτιαίο μυελό και αποτελεί άμεσο μέτρο της λειτουργικής ακεραιότητας των κινητικών οδών. Αυτή η ιδιαιτερότητα το καθιστά ανεκτίμητο εργαλείο σε χειρουργικές επεμβάσεις όπου υπάρχει υψηλός κίνδυνος βλάβης αυτών των οδών.

Το D-Wave χρησιμοποιείται κυρίως κατά τη διάρκεια χειρουργικών επεμβάσεων του νωτιαίου μυελού, ιδίως σε περιπτώσεις όπου υπάρχει κίνδυνος τραυματισμού των κινητικών οδών, όπως σε εκτομές όγκων ή διορθώσεις σκολίωσης. Με την παρακολούθηση του D-Wave, οι χειρουργοί μπορούν να λαμβάνουν άμεση ανατροφοδότηση σχετικά με τη λειτουργική κατάσταση της φλοιώδους-σπονδυλικής οδού. Ένα σταθερό πλάτος D-Wave κατά τη διάρκεια της χειρουργικής επέμβασης υποδεικνύει ότι οι κινητικές οδοί είναι άθικτες, ενώ μια σημαντική μείωση του πλάτους μπορεί να σηματοδοτήσει πιθανή βλάβη, προτρέποντας τη χειρουργική ομάδα να λάβει διορθωτικά μέτρα για την αποφυγή μόνιμων κινητικών ελλειμμάτων.

#### **Οφέλη από τη χρήση του D-Wave**

- **Ακρίβεια:** Το D-Wave παρέχει μια άμεση και αξιόπιστη αξιολόγηση της ακεραιότητας των κινητικών οδών, η οποία είναι ζωτικής σημασίας για τη διατήρηση της κινητικής λειτουργίας κατά τη διάρκεια χειρουργικών επεμβάσεων υψηλού κινδύνου.

- Ανατροφοδότηση σε πραγματικό χρόνο: Ο άμεσος χαρακτήρας της παρακολούθησης του D-Wave επιτρέπει τη λήψη γρήγορων διεγχειρητικών αποφάσεων, αποτρέποντας δυνητικά μη αναστρέψιμες νευρικές βλάβες.
- Προγνωστική αξία: Μετεγχειρητικά, η παρουσία σταθερού D-Wave συσχετίζεται με καλύτερη πρόγνωση για την αποκατάσταση της κινητικής λειτουργίας, προσφέροντας καθησυχασμό τόσο στη χειρουργική ομάδα όσο και στον ασθενή.

### **Περιορισμοί και προκλήσεις**

Παρά τα πλεονεκτήματά της, η χρήση του D-Wave στην IONM δεν είναι χωρίς προκλήσεις. Απαιτεί εξειδικευμένο εξοπλισμό και τεχνογνωσία για την ακριβή καταγραφή και ερμηνεία των σημάτων. Επιπλέον, το D-Wave μπορεί να είναι δύσκολο να ληφθεί σε ορισμένους ασθενείς λόγω ανατομικών παραλλαγών ή τεχνικών παραγόντων, περιορίζοντας τη χρήση του σε ορισμένα σενάρια(25).

## **1.5 Εφαρμογές της μηχανικής μάθησης στην ιατρική**

Η ιατρική απεικόνιση είναι ένας κρίσιμος τομέας της υγειονομικής περίθαλψης όπου η μηχανική μάθηση (ML) έχει σημειώσει σημαντική πρόοδο. Βελτιώνοντας την ακρίβεια και την αποτελεσματικότητα της ανάλυσης εικόνων, η ML έχει φέρει επανάσταση στην ανίχνευση, τη διάγνωση και τον προγραμματισμό της θεραπείας διαφόρων ιατρικών καταστάσεων. Αυτή η λεπτομερής ανάλυση διερευνά τις εφαρμογές, τις τεχνικές, τα οφέλη και τις προκλήσεις της ML στην ιατρική απεικόνιση.

### **1.5.1 Εφαρμογές της ML στην ιατρική απεικόνιση**

*-Ανίχνευση και ταξινόμηση όγκων:*

- **Καρκίνος του μαστού:** Οι αλγόριθμοι ML, ιδίως τα νευρωνικά δίκτυα συνελίξεων (CNN), χρησιμοποιούνται για την ανάλυση μαστογραφιών για την έγκαιρη ανίχνευση του καρκίνου του μαστού. Τα μοντέλα αυτά μπορούν να εντοπίσουν όγκους που μπορεί να διαφύγουν από τους ακτινολόγους.
- **Καρκίνος του πνεύμονα:** Μοντέλα βαθιάς μάθησης εφαρμόζονται σε αξονικές τομογραφίες για τον εντοπισμό οζιδίων του πνεύμονα και την ταξινόμησή τους ως καλοήθεις ή κακοήθεις. Τα συστήματα αυτά ενισχύουν την έγκαιρη ανίχνευση του καρκίνου του πνεύμονα, βελτιώνοντας τα ποσοστά επιβίωσης (26).

*-Απεικόνιση εγκεφάλου:*

- **Νόσος Alzheimer:** Μοντέλα ML αναλύουν σαρώσεις μαγνητικής τομογραφίας για τον εντοπισμό πρώιμων ενδείξεων της νόσου Αλτσχάιμερ, ανιχνεύοντας μοτίβα ατροφίας στον εγκέφαλο. Τα μοντέλα αυτά μπορούν να προβλέψουν την εξέλιξη της νόσου και να βοηθήσουν στην έγκαιρη παρέμβαση.(27)
- **Ανίχνευση εγκεφαλικών επεισοδίων:** Αλγόριθμοι ML αναλύουν σαρώσεις CT και MRI για τον γρήγορο εντοπισμό εγκεφαλικών επεισοδίων και την εκτίμηση της έκτασης της εγκεφαλικής βλάβης. Αυτή η ταχεία ανάλυση είναι ζωτικής σημασίας για την έγκαιρη θεραπεία και τη βελτίωση των αποτελεσμάτων των ασθενών .

*-Καρδιακή απεικόνιση:*

- **Καρδιακές παθήσεις:** Τα μοντέλα ML χρησιμοποιούνται για την ανάλυση ηχοκαρδιογραφημάτων και αγγειογραφιών CT για την ανίχνευση στεφανιαίας νόσου, ανωμαλιών των καρδιακών βαλβίδων και άλλων καρδιακών παθήσεων. Τα μοντέλα αυτά βοηθούν στην έγκαιρη διάγνωση και στον προγραμματισμό της θεραπείας.
- **Μαγνητική τομογραφία καρδιάς:** Οι τεχνικές βαθιάς μάθησης χρησιμοποιούνται για την κατάτμηση και ανάλυση εικόνων καρδιακής μαγνητικής τομογραφίας, παρέχοντας λεπτομερείς πληροφορίες σχετικά με τη δομή και τη λειτουργία της καρδιάς(28).

*-Οφθαλμολογία:*

- **Διαβητική αμφιβληστροειδοπάθεια:** Μοντέλα ML αναλύουν εικόνες αμφιβληστροειδούς για την ανίχνευση της διαβητικής αμφιβληστροειδοπάθειας σε πρώιμο στάδιο. Τα μοντέλα αυτά βοηθούν τους οφθαλμιάτρους στην παροχή έγκαιρης θεραπείας για την πρόληψη της απώλειας της όρασης.
- **Ανίχνευση γλαυκώματος:** Αλγόριθμοι ML αναλύουν εικόνες του οπτικού νεύρου για τον εντοπισμό σημείων γλαυκώματος, βοηθώντας στην έγκαιρη διάγνωση και διαχείριση (29)

*-Ορθοπαιδική απεικόνιση:*

- **Ανίχνευση καταγμάτων:** Μοντέλα ML χρησιμοποιούνται για την ανάλυση ακτίνων X και αξονικών τομογραφιών για την ανίχνευση καταγμάτων και οστικών ανωμαλιών. Τα μοντέλα αυτά βελτιώνουν τη διαγνωστική ακρίβεια και μειώνουν τον φόρτο εργασίας των ακτινολόγων.
- **Οστεοαρθρίτιδα:** Αλγόριθμοι ML αναλύουν εικόνες αρθρώσεων για την ανίχνευση πρώιμων ενδείξεων οστεοαρθρίτιδας, βοηθώντας στην έγκαιρη παρέμβαση και διαχείριση (30).

### 1.5.2 Τεχνικές που χρησιμοποιούνται στην ML για την ιατρική απεικόνιση

*Συνελικτικά νευρωνικά δίκτυα (CNN):*

- **Εφαρμογές:** CNNs χρησιμοποιούνται ευρέως στην ανίχνευση όγκων, στην απεικόνιση του εγκεφάλου και στην καρδιακή απεικόνιση λόγω της υψηλής ακρίβειας και αποδοτικότητάς τους στην ανάλυση εικόνων .

*Μηχανές διανυσμάτων στήριξης (SVM):*

- **Εφαρμογές:** SVMs χρησιμοποιούνται στην απεικόνιση του εγκεφάλου για την ταξινόμηση όγκων και στην οφθαλμολογία για την ανίχνευση της διαβητικής αμφιβληστροειδοπάθειας

*Τυχαία δάση και δέντρα αποφάσεων:*

- **Εφαρμογές:** Τα τυχαία δάση χρησιμοποιούνται στην ορθοπαιδική απεικόνιση για την ανίχνευση καταγμάτων και στην καρδιακή απεικόνιση για την ταξινόμηση καρδιακών παθήσεων(31).

### 1.5.3 Οφέλη της ML στην ιατρική απεικόνιση

#### **Ενισχυμένη διαγνωστική ακρίβεια:**

- **Ακρίβεια:** Τα μοντέλα ML συχνά ξεπερνούν τις ανθρώπινες επιδόσεις στην ανίχνευση λεπτών ανωμαλιών σε ιατρικές εικόνες, οδηγώντας σε πρωιμότερες και ακριβέστερες διαγνώσεις.
- **Συνέπεια:** Οι αλγόριθμοι ML παρέχουν συνεπή αποτελέσματα, μειώνοντας τη διακύμανση στις διαγνωστικές ερμηνείες μεταξύ διαφορετικών ακτινολόγων .
- **Αποδοτικότητα:** Η αυτοματοποιημένη ανάλυση εικόνας μειώνει σημαντικά τον χρόνο που απαιτείται για την ερμηνεία των ιατρικών εικόνων, επιτρέποντας ταχύτερη διάγνωση και σχεδιασμό της θεραπείας.
- **Μείωση του φόρτου εργασίας:** Χειριζόμενα τις συνήθεις εργασίες ανάλυσης εικόνας, τα μοντέλα ML απελευθερώνουν τους ακτινολόγους για να επικεντρωθούν σε πιο σύνθετες περιπτώσεις .
- **Δυνατότητα χειρισμού μεγάλου όγκου δεδομένων:** Τα μοντέλα ML μπορούν να επεξεργάζονται και να αναλύουν γρήγορα τεράστιους όγκους απεικονιστικών δεδομένων, γεγονός που είναι ιδιαίτερα επωφελές σε προγράμματα ελέγχου μεγάλης κλίμακας.
- **Ενσωμάτωση δεδομένων:** Οι αλγόριθμοι ML μπορούν να ενσωματώσουν δεδομένα από πολλαπλές απεικονιστικές μεθόδους, παρέχοντας μια πιο ολοκληρωμένη αξιολόγηση της κατάστασης του ασθενούς .

#### **Προκλήσεις στην ML για την ιατρική απεικόνιση**

##### *1.Υψηλές υπολογιστικές απαιτήσεις:*

- Εντατική χρήση πόρων: Η εκπαίδευση και η ανάπτυξη μοντέλων ML, ιδίως αλγορίθμων βαθιάς μάθησης, απαιτούν σημαντικούς υπολογιστικούς πόρους, συμπεριλαμβανομένων GPU υψηλής απόδοσης και μεγάλης χωρητικότητας μνήμης.
- Υποδομή: Η δημιουργία της απαραίτητης υποδομής για την ML στην ιατρική απεικόνιση μπορεί να είναι δαπανηρή και πολύπλοκη.

##### *2.Ανάγκη για μεγάλα σχολιασμένα σύνολα δεδομένων:*

- Εξάρτηση από τα δεδομένα: Τα μοντέλα ML απαιτούν μεγάλες ποσότητες σχολιασμένων δεδομένων για εκπαίδευση, ώστε να επιτευχθεί υψηλή ακρίβεια. Η συλλογή και ο σχολιασμός ιατρικών εικόνων είναι χρονοβόρα και δαπανηρή.
- Ποιότητα δεδομένων: Η διασφάλιση της ποιότητας και της συνέπειας των δεδομένων εκπαίδευσης είναι ζωτικής σημασίας για την απόδοση των μοντέλων ML.

##### *3.Ρυθμιστικά και ηθικά ζητήματα:*

- Απόρρητο των δεδομένων: Η διασφάλιση του απορρήτου και της ασφάλειας των δεδομένων των ασθενών που χρησιμοποιούνται στην εκπαίδευση των μοντέλων ML αποτελεί σημαντική ανησυχία.
- Μεροληψία και δικαιοσύνη: Τα μοντέλα ML μπορεί να διαιωνίζουν ακούσια τις προκαταλήψεις που υπάρχουν στα δεδομένα εκπαίδευσης, οδηγώντας σε άδικες ή ανακριβείς προβλέψεις. Η αντιμετώπιση αυτών των προκαταλήψεων είναι κρίσιμη για τη δίκαιη υγειονομική περίθαλψη



#### 1.5.4 Προβλεπτική ανάλυση και διάγνωση ασθενειών με χρήση μηχανικής μάθησης

Η προγνωστική ανάλυση με χρήση μηχανικής μάθησης (ML) περιλαμβάνει την ανάλυση ιστορικών δεδομένων και δεδομένων πραγματικού χρόνου για την πραγματοποίηση προβλέψεων σχετικά με μελλοντικά γεγονότα ή αποτελέσματα. Στον ιατρικό τομέα, η τεχνολογία αυτή χρησιμοποιείται για την πρόβλεψη της εμφάνισης, της εξέλιξης και των αποτελεσμάτων των ασθενών, ενισχύοντας έτσι την έγκαιρη διάγνωση, την εξατομικευμένη θεραπεία και τη συνολική φροντίδα των ασθενών. Αυτή η λεπτομερής ανάλυση διερευνά τις εφαρμογές, τις τεχνικές, τα οφέλη και τις προκλήσεις που σχετίζονται με την ML στην προγνωστική ανάλυση και τη διάγνωση ασθενειών.

#### *Εφαρμογές της ML στην προγνωστική ανάλυση και τη διάγνωση ασθενειών*

##### 1. Πρόβλεψη και διαχείριση του διαβήτη:

- Εφαρμογές: μοντέλα ML προβλέπουν την εμφάνιση διαβήτη αναλύοντας δεδομένα ασθενών, συμπεριλαμβανομένων γενετικών παραγόντων, τρόπου ζωής και ιστορικών ιατρικών αρχείων. Προβλέπουν επίσης τα επίπεδα γλυκόζης στο αίμα και συνιστούν δόσεις ινσουλίνης για διαβητικούς ασθενείς.
- Τεχνικές: Χρησιμοποιούνται συνήθως αλγόριθμοι όπως τα τυχαία δάση, οι μηχανές διανυσμάτων υποστήριξης (SVM) και τα νευρωνικά δίκτυα. Οι μέθοδοι ensemble που συνδυάζουν πολλαπλούς αλγορίθμους είναι ιδιαίτερα αποτελεσματικές(32).

##### 2. Πρόβλεψη καρδιαγγειακών παθήσεων:

- Εφαρμογές: Τα μοντέλα ML αναλύουν διάφορους παράγοντες κινδύνου, συμπεριλαμβανομένης της ηλικίας, της αρτηριακής πίεσης, των επιπέδων χοληστερόλης και των συνηθειών του τρόπου ζωής, για να προβλέψουν την πιθανότητα εμφάνισης καρδιαγγειακών νοσημάτων (CVD). Τα μοντέλα αυτά βοηθούν στην έγκαιρη διάγνωση και παρέμβαση.
- Τεχνικές: Η λογιστική παλινδρόμηση, τα δέντρα αποφάσεων και τα μοντέλα βαθιάς μάθησης χρησιμοποιούνται για την πρόβλεψη καρδιακών παθήσεων. Οι μέθοδοι ensemble και οι τεχνικές επιλογής χαρακτηριστικών ενισχύουν την ακρίβεια των μοντέλων(33).

##### 3. Διάγνωση και πρόγνωση του καρκίνου:

- Εφαρμογές: Μοντέλα ML ανιχνεύουν διάφορους τύπους καρκίνου, όπως ο καρκίνος του μαστού, του πνεύμονα και του δέρματος, από ιατρικές απεικονίσεις και γονιδιωματικά δεδομένα. Προβλέπουν επίσης την εξέλιξη του καρκίνου και τα ποσοστά επιβίωσης των ασθενών.
- Τεχνικές: Συνελκτικά νευρωνικά δίκτυα (CNN) για ανάλυση εικόνων και μηχανές διανυσμάτων υποστήριξης (SVM) και τυχαία δάση για ανάλυση γονιδιωματικών δεδομένων.

##### 4. Νευροεκφυλιστικές ασθένειες:

- Εφαρμογές: Τα μοντέλα ML βοηθούν στην έγκαιρη διάγνωση νευροεκφυλιστικών ασθενειών όπως η νόσος του Alzheimer και η νόσος του Parkinson, αναλύοντας εγκεφαλικές σαρώσεις, γενετικά δεδομένα και ιστορικά ασθενών. Μπορούν επίσης να προβλέψουν την εξέλιξη της νόσου και την ανταπόκριση στις θεραπείες.

- Τεχνικές: Οι τεχνικές βαθιάς μάθησης, ιδίως τα επαναλαμβανόμενα νευρωνικά δίκτυα (RNN) και τα δίκτυα μακράς βραχυπρόθεσμης μνήμης (LSTM), χρησιμοποιούνται για την ανάλυση διαδοχικών δεδομένων και δεδομένων χρονοσειρών.

#### **5. Πρόβλεψη εκδήλωσης επιδημιών μολυσματικών ασθενειών:**

- Εφαρμογές: Τα μοντέλα πρόβλεψης προβλέπουν τα ξεσπάσματα λοιμωδών νόσων όπως η γρίπη, το COVID-19 και ο δάγκειος πυρετός αναλύοντας επιδημιολογικά δεδομένα, πρότυπα ταξιδιών και κλιματικά δεδομένα.
- Τεχνικές: Η ανάλυση χρονοσειρών, η ενισχυτική μάθηση και η ανάλυση δικτύων χρησιμοποιούνται συνήθως σε αυτά τα μοντέλα(34).

#### **Τεχνικές που χρησιμοποιούνται στην ML για την προγνωστική ανάλυση**

##### **1. Τυχαία δάση:**

- Εφαρμογές: Καρδιαγγειακές παθήσεις και αποτελέσματα καρκίνου.

##### **2. Μηχανές διανυσμάτων υποστήριξης (SVM):**

- Εφαρμογές: Εφαρμόζονται σε εργασίες ταξινόμησης ασθενειών, όπως η ανίχνευση καρκίνου και η διάγνωση νευροεκφυλιστικών ασθενειών.

##### **3. Νευρωνικά δίκτυα και βαθιά μάθηση:**

- Εφαρμογές: Χρησιμοποιούνται ευρέως στην ανάλυση εικόνων για την ανίχνευση καρκίνου, στην ανάλυση χρονοσειρών για την πρόβλεψη της εξέλιξης ασθενειών και στην επεξεργασία φυσικής γλώσσας για την ανάλυση ιατρικών αρχείων.

##### **4. Λογιστική παλινδρόμηση:**

- Εφαρμογές: Χρησιμοποιείται συνήθως στην πρόβλεψη του κινδύνου ασθενειών όπως οι καρδιακές παθήσεις και ο διαβήτης με βάση τους παράγοντες κινδύνου του ασθενούς.

#### **Οφέλη της ML στην προγνωστική ανάλυση και τη διάγνωση ασθενειών**

##### **1. Έγκαιρη και ακριβής ανίχνευση ασθενειών:**

- Ακρίβεια: Τα μοντέλα ML μπορούν να εντοπίσουν λεπτά μοτίβα και συσχετίσεις σε ιατρικά δεδομένα που μπορεί να διαφύγουν από την ανθρώπινη ανάλυση, οδηγώντας σε πρώιμες και ακριβέστερες διαγνώσεις.
- Εξατομικευμένη περίθαλψη: Με την πρόβλεψη του κινδύνου και της εξέλιξης της νόσου, τα μοντέλα ML επιτρέπουν εξατομικευμένα σχέδια θεραπείας προσαρμοσμένα στις ανάγκες και τις συνθήκες του κάθε ασθενούς .

##### **2. Βελτιωμένα αποτελέσματα για τους ασθενείς:**

- Προληπτικές παρεμβάσεις: Η έγκαιρη πρόβλεψη του κινδύνου ασθένειας επιτρέπει έγκαιρες παρεμβάσεις, οι οποίες μπορούν να αποτρέψουν την εμφάνιση ή την εξέλιξη των ασθενειών.
- Βελτιστοποιημένες θεραπείες: Τα μοντέλα πρόβλεψης βοηθούν στην επιλογή των πιο αποτελεσματικών θεραπειών με βάση το ατομικό προφίλ του ασθενούς, βελτιώνοντας την πιθανότητα θετικών αποτελεσμάτων .

### 3. Αποτελεσματική αξιοποίηση των πόρων:

- Στοχευμένος έλεγχος: Τα μοντέλα ML μπορούν να εντοπίσουν άτομα υψηλού κινδύνου που θα επωφεληθούν περισσότερο από τον έλεγχο και τα προληπτικά μέτρα, βελτιστοποιώντας τη χρήση των ιατρικών πόρων.
- Κατανομή πόρων: Οι προγνωστικές αναλύσεις μπορούν να προβλέψουν τις απαιτήσεις υγειονομικής περίθαλψης, βοηθώντας στον καλύτερο σχεδιασμό και την κατανομή των ιατρικών πόρων και του προσωπικού .

### 4. Βελτιωμένη λήψη αποφάσεων:

- Διαπιστώσεις βάσει δεδομένων: μοντέλα ML παρέχουν στους επαγγελματίες της υγειονομικής περίθαλψης πληροφορίες βάσει δεδομένων, υποστηρίζοντας τη λήψη αποφάσεων με βάση τα αποδεικτικά στοιχεία.
- Παρακολούθηση σε πραγματικό χρόνο: Η συνεχής παρακολούθηση και ανάλυση των δεδομένων των ασθενών επιτρέπει προσαρμογές σε πραγματικό χρόνο στα σχέδια θεραπείας και στις παρεμβάσεις .

## Προκλήσεις στην ML για την προγνωστική ανάλυση

### 1. Ιδιωτικότητα και ασφάλεια δεδομένων:

- Ανησυχίες: Η διασφάλιση της ιδιωτικότητας και της ασφάλειας των δεδομένων των ασθενών αποτελεί σημαντική πρόκληση, ιδίως όταν πρόκειται για σύνολα δεδομένων μεγάλης κλίμακας που περιέχουν ευαίσθητες πληροφορίες.
- Λύσεις: Η εφαρμογή ισχυρής κρυπτογράφησης δεδομένων, ελέγχων πρόσβασης και συμμόρφωσης με κανονισμούς όπως ο HIPAA και ο GDPR είναι ζωτικής σημασίας για την προστασία των δεδομένων των ασθενών .

### 2. Μεροληψία και δικαιοσύνη:

- Ζητήματα: Τα μοντέλα ML μπορεί να κληρονομήσουν προκαταλήψεις που υπάρχουν στα δεδομένα εκπαίδευσης, οδηγώντας σε άδικες ή ανακριβείς προβλέψεις για ορισμένες ομάδες ασθενών.
- Προσεγγίσεις: Τεχνικές όπως η ανίχνευση μεροληψίας, οι περιορισμοί δικαιοσύνης και τα ποικίλα σύνολα δεδομένων εκπαίδευσης είναι απαραίτητες για την αντιμετώπιση και τον μετριασμό των μεροληψιών στα μοντέλα πρόβλεψης .

### 3. Ενσωμάτωση με τις κλινικές ροές εργασίας:

- Προκλήσεις: Η ενσωμάτωση των μοντέλων ML στις υπάρχουσες κλινικές ροές εργασίας μπορεί να είναι πολύπλοκη, απαιτώντας αλλαγές στην υποδομή, την εκπαίδευση και τις διαδικασίες.
- Στρατηγικές: Η ανάπτυξη φιλικών προς το χρήστη διεπαφών, η παροχή εκπαίδευσης κλινικών ιατρών και η διασφάλιση της διαλειτουργικότητας με τα συστήματα ηλεκτρονικών αρχείων υγείας (EHR) μπορούν να διευκολύνουν την ομαλότερη ενσωμάτωση .

### 4. Ερμηνευσιμότητα του μοντέλου:

- Λύσεις: Η ανάπτυξη επεξηγήσιμων τεχνικών τεχνητής νοημοσύνης (ΧΑΙ) για να καταστούν τα μοντέλα ML πιο διαφανή και κατανοητά στους κλινικούς γιατρούς είναι ζωτικής σημασίας για την απόκτηση εμπιστοσύνης και τη διασφάλιση της ακριβούς λήψης κλινικών αποφάσεων .

### 1.5.5 Γονιδιωματική και εξατομικευμένη ιατρική με χρήση μηχανικής μάθησης

Η γονιδιωματική και η εξατομικευμένη ιατρική είναι ταχέως εξελισσόμενοι τομείς που αξιοποιούν τη μηχανική μάθηση (ML) για την ανάλυση γενετικών δεδομένων και την ανάπτυξη εξατομικευμένων θεραπειών για άτομα με βάση το μοναδικό γενετικό τους προφίλ. Αυτή η ενότητα διερευνά τις εφαρμογές, τις τεχνικές, τα οφέλη και τις προκλήσεις της ML στη γονιδιωματική και την εξατομικευμένη ιατρική.

#### **Εφαρμογές της ML στη γονιδιωματική και την εξατομικευμένη ιατρική**

##### **1. Ανάλυση γενετικών παραλλαγών:**

- Εφαρμογές: Τα μοντέλα ML χρησιμοποιούνται για τον εντοπισμό και την ερμηνεία γενετικών παραλλαγών που σχετίζονται με ασθένειες. Αναλύοντας μεγάλα σύνολα γονιδιωματικών δεδομένων, τα μοντέλα αυτά μπορούν να προβλέψουν ποιες παραλλαγές είναι πιθανό να προκαλούν ή να συμβάλλουν σε συγκεκριμένες καταστάσεις υγείας.
- Τεχνικές: Αλγόριθμοι όπως οι μηχανές διανυσμάτων υποστήριξης (SVM), η βαθιά μάθηση και τα τυχαία δάση χρησιμοποιούνται για την ανάλυση δεδομένων ακολουθίας και την ταξινόμηση παραλλαγών(35).

##### **2. Προβλεπτική γονιδιωματική:**

- Εφαρμογές: Τα μοντέλα ML προβλέπουν την ευαισθησία ενός ατόμου σε ορισμένες ασθένειες με βάση τη γενετική του σύνθεση. Οι προβλέψεις αυτές βοηθούν στην έγκαιρη ανίχνευση και την προληπτική υγειονομική περίθαλψη.
- Τεχνικές: Χρησιμοποιούνται συνήθως τεχνικές όπως οι πολυγονιδιακές βαθμολογίες κινδύνου (PRS), οι οποίες συνδυάζουν τις επιδράσεις πολλαπλών γενετικών παραλλαγών, και τα νευρωνικά δίκτυα(36).

##### **3. Φαρμακογονιδιωματική:**

- Εφαρμογές: Τα μοντέλα ML αναλύουν γενετικά δεδομένα για να προβλέψουν πώς τα άτομα θα ανταποκριθούν σε συγκεκριμένα φάρμακα, βοηθώντας στην προσαρμογή των φαρμακευτικών θεραπειών με βάση τα γενετικά προφίλ.
- Τεχνικές: Τα δέντρα αποφάσεων, τα τυχαία δάση και τα μοντέλα βαθιάς μάθησης χρησιμοποιούνται για την ανάλυση γενετικών δεικτών που επηρεάζουν τον μεταβολισμό και την αποτελεσματικότητα των φαρμάκων(37).

##### **4. Γονιδιωματική του καρκίνου:**

- Εφαρμογές: Τα μοντέλα ML αναλύουν τις γενετικές μεταλλάξεις και αλλοιώσεις στα καρκινικά κύτταρα για τον εντοπισμό πιθανών στόχων για θεραπεία και την πρόβλεψη της πρόγνωσης των ασθενών. Τα μοντέλα αυτά βοηθούν στην ανάπτυξη εξατομικευμένων θεραπειών για τον καρκίνο.
- Τεχνικές: Συνελικτικά νευρωνικά δίκτυα (CNNs) για ανάλυση εικόνων και μέθοδοι μάθησης συνόλου για την ενσωμάτωση δεδομένων πολυ-ομικής(38).

##### **5. Διάγνωση σπάνιων ασθενειών:**

- Εφαρμογές: Τα μοντέλα ML βοηθούν στη διάγνωση σπάνιων γενετικών ασθενειών με την ανάλυση των γονιδιωμάτων των ασθενών και τον εντοπισμό μοναδικών γενετικών προτύπων που σχετίζονται με αυτές τις καταστάσεις.

- Τεχνικές: Αλγόριθμοι μηχανικής μάθησης, όπως οι k-κοντινότεροι γείτονες (KNN), οι SVM και η βαθιά μάθηση, χρησιμοποιούνται για την ανάλυση σύνθετων γενετικών δεδομένων.

### ***Τεχνικές που χρησιμοποιούνται στην ML για τη γονιδιωματική και την εξατομικευμένη ιατρική***

#### **1. Μηχανές διανυσμάτων υποστήριξης (SVM):**

- Εφαρμογές: Χρησιμοποιούνται στην ταξινόμηση γενετικών παραλλαγών και στην πρόβλεψη ασθενειών με βάση γενετικά προφίλ.
- Οφέλη: Αποτελεσματικές σε χώρους υψηλών διαστάσεων, ανθεκτικές στην υπερπροσαρμογή και ικανές να χειρίζονται μη γραμμικές σχέσεις σε γενετικά δεδομένα .

#### **2. Βαθιά μάθηση:**

- Εφαρμογές: Χρησιμοποιούνται ευρέως στη γονιδιωματική του καρκίνου, τη φαρμακογονιδιωματική και την προγνωστική γονιδιωματική για την ανάλυση συνόλων γονιδιωματικών δεδομένων μεγάλης κλίμακας και δεδομένων πολλαπλής γονιδιωματικής.
- Οφέλη: Ικανότητα εκμάθησης σύνθετων μοτίβων, υψηλή ακρίβεια σε σύνολα δεδομένων μεγάλης κλίμακας και δυνατότητα προσαρμογής σε διάφορους τύπους γονιδιωματικών δεδομένων .

#### **3. Τυχαία δάση:**

- Εφαρμογές: στη διάγνωση σπάνιων ασθενειών για την ταξινόμηση γενετικών παραλλαγών.

#### **4. Πολυγονιδιακές βαθμολογίες κινδύνου (PRS):**

- Εφαρμογές: Χρησιμοποιούνται στην προγνωστική γονιδιωματική για την εκτίμηση του κινδύνου ασθενειών όπως ο διαβήτης, οι καρδιαγγειακές παθήσεις και ορισμένοι καρκίνοι.
- Οφέλη: Παρέχει μια ολοκληρωμένη εκτίμηση κινδύνου με βάση γενετικά δεδομένα, επιτρέποντας την εξατομικευμένη προληπτική υγειονομική περίθαλψη .

#### **5. Συνελκτικά νευρωνικά δίκτυα (CNN):**

- Εφαρμογές: Χρησιμοποιούνται στη γονιδιωματική του καρκίνου για την ανάλυση ιστοπαθολογικών εικόνων και τον εντοπισμό γενετικών μεταλλάξεων.
- Οφέλη: Υψηλή ακρίβεια στην ανάλυση εικόνων, ικανότητα ανίχνευσης λεπτών μοτίβων σε γενετικά δεδομένα και αποτελεσματικότητα σε γονιδιωματικές μελέτες μεγάλης κλίμακας .

### ***Οφέλη του ML στη γονιδιωματική και την εξατομικευμένη ιατρική***

#### **1. Ενισχυμένη Ιατρική Ακρίβειας:**

- Εξατομικευμένες θεραπείες: Η ML επιτρέπει την ανάπτυξη εξατομικευμένων θεραπευτικών σχεδίων με βάση τη γενετική σύσταση ενός ατόμου, βελτιώνοντας την αποτελεσματικότητα της θεραπείας και μειώνοντας τις ανεπιθύμητες ενέργειες
- Στοχευμένες θεραπείες: Ο εντοπισμός γενετικών στόχων για θεραπείες επιτρέπει την ανάπτυξη στοχευμένων θεραπειών, ιδίως στην ογκολογία, οδηγώντας σε καλύτερα αποτελέσματα για τους ασθενείς .

## **2.Βελτιωμένη πρόβλεψη και πρόληψη ασθενειών:**

- Έγκαιρη ανίχνευση: Τα μοντέλα ML μπορούν να προβλέψουν τον κίνδυνο ασθενειών πριν από την εμφάνιση συμπτωμάτων, επιτρέποντας την έγκαιρη παρέμβαση και στρατηγικές πρόληψης.
- Προληπτική υγειονομική περίθαλψη: Με τον εντοπισμό ατόμων υψηλού κινδύνου, οι πάροχοι υγειονομικής περίθαλψης μπορούν να εφαρμόσουν προληπτικά μέτρα για την πρόληψη της εκδήλωσης ασθενειών, βελτιώνοντας τη συνολική δημόσια υγεία .

## **3.Βελτιστοποιημένη ανάπτυξη και χρήση φαρμάκων:**

- Φαρμακογονιδιωματική: Τα μοντέλα ML προβλέπουν πώς τα άτομα θα ανταποκριθούν σε συγκεκριμένα φάρμακα, βοηθώντας στην προσαρμογή των φαρμακευτικών θεραπειών και των δοσολογιών για μέγιστη αποτελεσματικότητα και ελάχιστες παρενέργειες.
- Ανακάλυψη φαρμάκων: Η ML επιταχύνει τη διαδικασία ανακάλυψης φαρμάκων, εντοπίζοντας δυνητικά υποψήφια φάρμακα και προβλέποντας την αποτελεσματικότητά τους με βάση γενετικά δεδομένα .

## **4.Ενισχυμένη έρευνα και κατανόηση:**

- Γονιδιωματική έρευνα: Η ML διευκολύνει την ανάλυση γονιδιωματικών δεδομένων μεγάλης κλίμακας, αποκαλύπτοντας νέες γνώσεις σχετικά με τη γενετική βάση των ασθενειών και βοηθώντας στην ανακάλυψη νέων βιοδεικτών
- Ενσωμάτωση πολλαπλών οπτικών συστημάτων: .

## **Προκλήσεις στην ML για τη γονιδιωματική και την εξατομικευμένη ιατρική**

### **1.Ιδιωτικότητα και ασφάλεια δεδομένων:**

- Ανησυχίες: Η προστασία της ιδιωτικής ζωής και της ασφάλειας των γενετικών δεδομένων είναι υψίστης σημασίας, δεδομένης της ευαίσθητης φύσης τους και της πιθανότητας κατάχρησης.
- Λύσεις: Η εφαρμογή ισχυρών μεθόδων κρυπτογράφησης, ελέγχων πρόσβασης και η συμμόρφωση με κανονισμούς προστασίας δεδομένων, όπως ο GDPR και ο HIPAA, είναι απαραίτητη .

### **2.Ηθικές εκτιμήσεις:**

- Ζητήματα: Οι δεοντολογικές ανησυχίες περιλαμβάνουν το ενδεχόμενο γενετικών διακρίσεων, τη συγκατάθεση μετά από ενημέρωση και την υπεύθυνη χρήση των γενετικών πληροφοριών.
- Προσεγγίσεις: Η ανάπτυξη δεοντολογικών κατευθυντήριων γραμμών και πολιτικών για τη διασφάλιση της δίκαιης και υπεύθυνης χρήσης των γενετικών δεδομένων σε εφαρμογές ML είναι ζωτικής σημασίας

• .

### **3.Μεροληψία και δικαιοσύνη:**

- Προκλήσεις: Τα μοντέλα ML μπορεί να κληρονομήσουν προκαταλήψεις που υπάρχουν στα δεδομένα εκπαίδευσης, οδηγώντας σε ανακριβείς προβλέψεις για ορισμένους πληθυσμούς.

- Προσεγγίσεις: Η εξασφάλιση ποικίλων και αντιπροσωπευτικών συνόλων δεδομένων εκπαίδευσης και η εφαρμογή τεχνικών για την ανίχνευση και τον μετριάσμό των προκαταλήψεων είναι απαραίτητες για δίκαια και ακριβή μοντέλα .

#### **4. Ενσωμάτωση με κλινικές ροές εργασίας:**

- Προκλήσεις: Η ενσωμάτωση των μοντέλων ML στην κλινική πρακτική απαιτεί απρόσκοπτη ενσωμάτωση με τα υπάρχοντα συστήματα, εκπαίδευση των κλινικών ιατρών και προσαρμογές των ροών εργασίας.
- Στρατηγικές: Η ανάπτυξη φιλικών προς τον χρήστη διεπαφών, η διασφάλιση της διαλειτουργικότητας με τα ηλεκτρονικά αρχεία υγείας (EHR) και η παροχή ολοκληρωμένης κατάρτισης για τους επαγγελματίες του τομέα της υγείας μπορούν να διευκολύνουν την ενσωμάτωση .

#### **5. Πολυπλοκότητα των γονιδιωματικών δεδομένων:**

- Προκλήσεις: Τα γονιδιωματικά δεδομένα είναι εξαιρετικά πολύπλοκα και ετερογενή, γεγονός που καθιστά δύσκολη την ακριβή ανάλυση και ερμηνεία τους.
- Λύσεις: Απαιτούνται προηγμένες υπολογιστικές μέθοδοι και ισχυρές τεχνικές προεπεξεργασίας δεδομένων για τον αποτελεσματικό χειρισμό της πολυπλοκότητας και της μεταβλητότητας των γονιδιωματικών δεδομένων .

## **1.6 Εφαρμογές της μηχανικής μάθησης στην ενδοεγχειρητική νευροπαρακολούθηση**

### **1.6.1 Μελέτη 1: Εφαρμογή της μηχανικής μάθησης στην IONM για τη χειρουργική της σπονδυλικής στήλης(39)**

Η χειρουργική επέμβαση της σπονδυλικής στήλης συχνά ενέχει σημαντικούς κινδύνους για τον νωτιαίο μυελό και τις νευρικές ρίζες, οδηγώντας ενδεχομένως σε μετεγχειρητικά νευρολογικά ελλείμματα. Η διεγχειρητική νευροπαρακολούθηση (IONM) χρησιμοποιείται για τον μετριάσμό αυτών των κινδύνων παρέχοντας ανατροφοδότηση σε πραγματικό χρόνο σχετικά με τη νευρική λειτουργία. Η παρούσα μελέτη διερευνά την εφαρμογή τεχνικών μηχανικής μάθησης (ML) για την ενίσχυση της αποτελεσματικότητας της IONM, εστιάζοντας ιδιαίτερα στην επίδραση του αναισθητικού παράγοντα σεβοφλουράνιο στα σωματοαισθητικά προκλητά δυναμικά (SSEP) κατά τη διάρκεια χειρουργικής επέμβασης στη σπονδυλική στήλη.

#### ***Ερευνητική εστίαση***

Ο πρωταρχικός στόχος αυτής της μελέτης ήταν να αναλυθεί πώς οι διαφορετικές συγκεντρώσεις σεβοφλουρανίου, ενός αναισθητικού παράγοντα, επηρεάζουν τις SSEPs κατά τη διάρκεια της χειρουργικής επέμβασης στη σπονδυλική στήλη. Η μελέτη αποσκοπούσε στην ανάπτυξη μοντέλων ML ικανών να προβλέπουν τις αλλαγές στις κυματομορφές SSEP, βελτιώνοντας έτσι την ακρίβεια και την αξιοπιστία της IONM υπό διαφορετικές αναισθητικές συνθήκες.

#### ***Μεθοδολογία***

*1. Συλλογή δεδομένων:*

- Συλλέχθηκαν δεδομένα SSEP από 10 ασθενείς που υποβλήθηκαν σε διάφορες επεμβάσεις στη σπονδυλική στήλη.
- Πραγματοποιήθηκαν πολλαπλές καταγραφές SSEP σε διαφορετικές συγκεντρώσεις σεβοφλουρανίου για να καταγραφεί ένα ευρύ φάσμα αποκρίσεων.

*2. Εξαγωγή χαρακτηριστικών:*

- Ανάλυση κύριων συνιστωσών (PCA): Χρησιμοποιήθηκε για τη μείωση της διαστατικότητας των δεδομένων SSEP, διατηρώντας παράλληλα τη σημαντικότερη διακύμανση.
- Καμπύλες χώρου φάσης (PSC): Παροχή γεωμετρικής αναπαράστασης της δυναμικής του σήματος SSEP.
- Ανάλυση χρόνου-συχνότητας (TFA): Ανέλυσε τα σήματα SSEP τόσο στο πεδίο του χρόνου όσο και στο πεδίο της συχνότητας για την καταγραφή των μεταβατικών χαρακτηριστικών.

*3. Επιλογή χαρακτηριστικών:*

- Ελάχιστος πλεονασμός μέγιστη συνάφεια (MRMR): Αυτή η τεχνική χρησιμοποιήθηκε για την επιλογή των πιο κατατοπιστικών χαρακτηριστικών που ήταν ελάχιστα περιττά, εξασφαλίζοντας ότι οι εισροές του μοντέλου παρείχαν τη μέγιστη δυνατή πληροφορία για τη μεταβλητή εξόδου (μεταβολές SSEP).

*4. Μοντέλα μηχανικής μάθησης:*

- Γραμμική παλινδρόμηση: Ένα βασικό μοντέλο που χρησιμοποιείται για τη δημιουργία μιας βάσης για την πρόβλεψη των αλλαγών στις SSEPs.
- Δέντρα παλινδρόμησης: Παρέχουν μια μη γραμμική προσέγγιση, αποτυπώνοντας πολύπλοκες αλληλεπιδράσεις μεταξύ των χαρακτηριστικών.
- Μηχανές διανυσμάτων υποστήριξης (SVM): Χρησιμοποιήθηκαν για την ευρωστία τους στο χειρισμό δεδομένων υψηλών διαστάσεων και τη σύλληψη μη γραμμικών σχέσεων.
- Νευρωνικά δίκτυα: Χρησιμοποιήθηκαν για τη μοντελοποίηση ιδιαίτερα πολύπλοκων, μη γραμμικών αλληλεπιδράσεων εντός των δεδομένων.

**Αποτελέσματα**

*1. Απόδοση του μοντέλου:*

- Τα μοντέλα SVM και δέντρου παλινδρόμησης επέδειξαν ανώτερη απόδοση σε σύγκριση με τη γραμμική παλινδρόμηση και τα νευρωνικά δίκτυα, που υποδεικνύεται από τις χαμηλότερες τιμές μέσου τετραγωνικού σφάλματος (RMSE). Αυτό υποδηλώνει ότι αυτά τα μοντέλα ήταν πιο ακριβή στην πρόβλεψη των αλλαγών στις κυματομορφές SSEP λόγω των διαφορετικών συγκεντρώσεων σεβοφλουρανίου.



- Τα SVM έδειξαν υψηλή ακρίβεια λόγω της ικανότητάς τους να χειρίζονται την υψηλής διάστασης, μη γραμμική φύση των δεδομένων SSEP.
- Τα δέντρα παλινδρόμησης παρείχαν ερμηνεύσιμα μοντέλα που ανέδειξαν τα βασικά χαρακτηριστικά που επηρεάζουν τις μεταβολές της SSEP, γεγονός που είναι ζωτικής σημασίας για τη λήψη κλινικών αποφάσεων.

#### **Κλινικές επιπτώσεις:**

- ❖ Η ικανότητα των μοντέλων ML να προβλέπουν την επίδραση των αναισθητικών παραγόντων στα σήματα IONM επιτρέπει την καλύτερη διαχείριση της αναισθησίας κατά τη διάρκεια της χειρουργικής επέμβασης, μειώνοντας δυνητικά τον κίνδυνο νευρικού συμβιβασμού.
- ❖ Με την ενσωμάτωση αυτών των μοντέλων ML στα συστήματα IONM, μπορούν να γίνουν προσαρμογές της αναισθησίας σε πραγματικό χρόνο, βελτιώνοντας τη συνολική ασφάλεια και αποτελεσματικότητα των χειρουργικών επεμβάσεων σπονδυλικής στήλης.

### **1.6.2 Μελέτη 2: Μηχανική μάθηση για ταξινόμηση σημάτων στην ενδοεγχειρητική νευροπαρακολούθηση (IONM)**

#### **Ερευνητική εστίαση**

Ο πρωταρχικός στόχος αυτής της μελέτης ήταν να αναπτυχθούν και να αξιολογηθούν μοντέλα ML για την ταξινόμηση διαφόρων νευροφυσιολογικών σημάτων που καταγράφονται κατά τη διάρκεια χειρουργικών επεμβάσεων. Με την αυτοματοποίηση της διαδικασίας ταξινόμησης των σημάτων, η μελέτη αποσκοπούσε στη μείωση του εργασιακού φόρτου των νευροφυσιολόγων και στη βελτίωση της ακρίβειας και της συνέπειας της διεγχειρητικής παρακολούθησης.

Μεθοδολογία(40)

#### **1.Συλλογή δεδομένων:**

- ❖ Πηγή: Τα νευροφυσιολογικά δεδομένα, συμπεριλαμβανομένων των EMG, EEG, SSEP και MEP, συλλέχθηκαν από ασθενείς που υποβλήθηκαν σε διαφορετικούς τύπους χειρουργικών επεμβάσεων.
- ❖ Όγκος: Συγκεντρώθηκε ένα μεγάλο σύνολο δεδομένων που αποτελείται από χιλιάδες καταγραφές σημάτων, ώστε να διασφαλιστεί η ισχυρή εκπαίδευση και αξιολόγηση των μοντέλων ML.

#### **2.Προεπεξεργασία:**

- ❖ Μείωση θορύβου: Για τη βελτίωση της ποιότητας του σήματος εφαρμόστηκαν τεχνικές όπως το ζωνοπερατό φίλτράρισμα και η αφαίρεση θορύβου.
- ❖ Κανονικοποίηση: Τα σήματα κανονικοποιήθηκαν για να εξασφαλιστεί η ομοιομορφία και να διευκολυνθεί η εκπαίδευση του μοντέλου.

#### **3.Εξαγωγή χαρακτηριστικών:**

- ❖ Χαρακτηριστικά στο πεδίο του χρόνου: Από τα σήματα εξήχθησαν το πλάτος, η καθυστέρηση και το σχήμα της κυματομορφής.
- ❖ Χαρακτηριστικά στο πεδίο της συχνότητας: Οι φασματικές συνιστώσες ισχύος και συχνότητας αναλύθηκαν με τη χρήση μετασχηματισμού Fourier και μετασχηματισμού κυματιδίου.
- ❖ Χαρακτηριστικά χρόνου-συχνότητας: Χρησιμοποιήθηκαν ο μετασχηματισμός Fourier μικρού χρόνου (STFT) και ο μετασχηματισμός wavelet για να καταγραφούν τόσο τα χρονικά όσο και τα συχνοτικά χαρακτηριστικά των σημάτων.

#### 4. Μοντέλα μηχανικής μάθησης:

- ❖ Συνελκτικά νευρωνικά δίκτυα (CNN): Χρησιμοποιήθηκαν για την ικανότητά τους να μαθαίνουν αυτόματα χωρικές ιεραρχίες χαρακτηριστικών από δεδομένα εισόδου, καθιστώντας τα κατάλληλα για δεδομένα που μοιάζουν με εικόνες, όπως τα σήματα EEG και EMG.
- ❖ Δέντρα απόφασης: Επιλέχθηκαν για την απλότητα και την ερμηνευσιμότητά τους, επιτρέποντας την εύκολη κατανόηση των κανόνων ταξινόμησης.
- ❖ Μηχανές διανυσμάτων υποστήριξης (SVM): Χρησιμοποιούνται για την ευελιξία τους στο χειρισμό δεδομένων υψηλών διαστάσεων και είναι αποτελεσματικές σε εργασίες δυαδικής ταξινόμησης.
- ❖ Τυχαία δάση: για τη βελτίωση της προβλεπτικής απόδοσης και τον έλεγχο της υπερπροσαρμογής.

#### 5. Μετρικές αξιολόγησης:

- ❖ Ακρίβεια: Το ποσοστό των αληθώς θετικών ταξινομήσεων μεταξύ όλων των θετικών ταξινομήσεων.
- ❖ Ανάκληση: Το ποσοστό των αληθώς θετικών ταξινομήσεων μεταξύ όλων των πραγματικών θετικών περιπτώσεων.
- ❖ F1-Score: Ο αρμονικός μέσος όρος της ακρίβειας και της ανάκλησης, παρέχοντας ένα ισορροπημένο μέτρο της απόδοσης του μοντέλου.
- ❖ Περιοχή κάτω από τη χαρακτηριστική καμπύλη λειτουργίας δέκτη (AUC-ROC): Ένα μέτρο της ικανότητας του μοντέλου να διακρίνει μεταξύ κλάσεων.

### Αποτελέσματα

#### 1. Απόδοση μοντέλου:

- ❖ Συνελκτικά νευρωνικά δίκτυα (CNN): Πέτυχαν υψηλή ακρίβεια στην ταξινόμηση σύνθετων νευροφυσιολογικών σημάτων, ξεπερνώντας τις παραδοσιακές μεθόδους. Τα CNNs επέδειξαν AUC-ROC 0,95, υποδεικνύοντας εξαιρετική διακριτική ικανότητα.
- ❖ Δέντρα απόφασης: Παρείχαν ερμηνεύσιμα αποτελέσματα με ακρίβεια 0,85. Η απλότητα και η ερμηνευσιμότητα των δέντρων απόφασης τα καθιστούν πολύτιμα για τη λήψη κλινικών αποφάσεων.

- ❖ Μηχανές διανυσμάτων υποστήριξης (SVM): Παρουσίασαν ισχυρή απόδοση με ακρίβεια 0,90, αντιμετωπίζοντας αποτελεσματικά την υψηλή διαστατική φύση των δεδομένων.
- ❖ Τυχαία δάση: Παρουσίασαν την καλύτερη συνολική απόδοση με ακρίβεια 0,92, συνδυάζοντας τα πλεονεκτήματα πολλαπλών δέντρων απόφασης για την ενίσχυση της ακρίβειας πρόβλεψης και τη μείωση της υπερπροσαρμογής.

## 2. Κλινικές επιπτώσεις:

- ❖ Αυτοματοποιημένη ταξινόμηση σημάτων: Η χρήση μοντέλων ML για την αυτοματοποιημένη ταξινόμηση σήματος μπορεί να μειώσει σημαντικά το γνωστικό φορτίο των νευροφυσιολόγων, επιτρέποντάς τους να επικεντρωθούν σε πιο κρίσιμες πτυχές της διεγχειρητικής παρακολούθησης.
- ❖ Βελτιωμένη αξιοπιστία: Τα μοντέλα ML παρέχουν συνεπείς και ακριβείς ταξινομήσεις, μειώνοντας τη μεταβλητότητα στις ερμηνείες που μπορεί να προκύψει με τη χειροκίνητη ανάλυση.
- ❖ Ανατροφοδότηση σε πραγματικό χρόνο: Η ενσωμάτωση των μοντέλων ML στα συστήματα IONM μπορεί να παρέχει ανατροφοδότηση σε πραγματικό χρόνο σχετικά με τη νευρική λειτουργία, ενισχύοντας την ασφάλεια και την αποτελεσματικότητα των χειρουργικών διαδικασιών.

### 1.6.3 Μελέτη 3 Ποσοτικός προσδιορισμός κοιλιακών/ραχιαίων νεύρων μέσω διεγχειρητικής νευροφυσιολογικής παρακολούθησης με επιβλεπόμενη μηχανική μάθηση

#### 1. Εισαγωγή

Η ενσωμάτωση της μηχανικής μάθησης (ML) στην διεγχειρητική παρακολούθηση (IONM) αποτελεί σημαντική πρόοδο στον τομέα της χειρουργικής περίθαλψης. Η εστίαση της παρούσας μελέτης στον ποσοτικό προσδιορισμό των κοιλιακών και ραχιαίων νευρικών ριζών κατά τη διάρκεια διαδικασιών επιλεκτικής ραχιαίας ριζοτομής (SDR) είναι ιδιαίτερα σημαντική λόγω της πολυπλοκότητας και του υψηλού κινδύνου αυτών των χειρουργικών επεμβάσεων. Στην SDR, η ακριβής ταυτοποίηση των νευρικών ινών είναι ζωτικής σημασίας για την αποφυγή βλάβης των κινητικών οδών, η οποία θα μπορούσε να οδηγήσει σε σοβαρά μετεγχειρητικά ελλείμματα. Με την εισαγωγή τεχνικών μηχανικής μάθησης με επίβλεψη στη διαδικασία, η παρούσα έρευνα συμβάλλει στον ευρύτερο στόχο της ενίσχυσης της χειρουργικής ακρίβειας και της βελτίωσης των αποτελεσμάτων των ασθενών(41).

Η χρήση της ML σε αυτό το πλαίσιο δεν αποτελεί απλώς μια σταδιακή βελτίωση αλλά μια πιθανή παραδειγματική αλλαγή. Οι παραδοσιακές μέθοδοι αναγνώρισης νεύρων βασίζονται σε μεγάλο βαθμό στην εμπειρογνωμοσύνη του χειρουργού και στην ερμηνεία των ηλεκτροφυσιολογικών σημάτων από τον νευροφυσιολόγο, οι οποίες μπορεί να είναι υποκειμενικές και επιρρεπείς στη μεταβλητότητα. Το ML προσφέρει μια αντικειμενική, καθοδηγούμενη από δεδομένα προσέγγιση που μπορεί να τυποποιήσει και ενδεχομένως να βελτιώσει την ακρίβεια αυτών των κρίσιμων αποφάσεων.

#### 2. Μεθοδολογία και εφαρμογή

Η μεθοδολογία που χρησιμοποιήθηκε στην παρούσα μελέτη είναι αυστηρή και κατάλληλη για τις προκλήσεις της διεγχειρητικής παρακολούθησης. Η ανάλυση των δεδομένων της μελέτης από 101 ασθενείς παρέχει ένα ισχυρό σύνολο δεδομένων για την εκπαίδευση και την επικύρωση των μοντέλων ML. Η εστίαση σε βασικές νευροφυσιολογικές παραμέτρους - όπως το κατώφλι, τα σύνθετα δυναμικά μυϊκής δράσης (CMAP) και ο λανθάνων χρόνος- διασφαλίζει ότι τα μοντέλα βασίζονται σε κλινικά συναφή δεδομένα.

Επιλογή μοντέλων μηχανικής μάθησης με επίβλεψη, συμπεριλαμβανομένων των δέντρων απόφασης, της λογιστικής παλινδρόμησης, των μηχανών διανυσμάτων υποστήριξης, των k- κοντινότερων γειτόνων και των νευρωνικών δικτύων, καλύπτει ένα ευρύ φάσμα πολυπλοκότητας και ερμηνευσιμότητας. Αυτή η ποικιλόμορφη προσέγγιση επιτρέπει στους ερευνητές να συγκρίνουν τις επιδόσεις απλών, εύκολα ερμηνεύσιμων μοντέλων με πιο σύνθετα μοντέλα που μπορεί να αποτυπώνουν λεπτότερα μοτίβα στα δεδομένα.

- Δέντρα αποφάσεων (DA): Αυτά τα μοντέλα προσφέρουν μια σαφή, ερμηνεύσιμη διαδικασία λήψης αποφάσεων, η οποία είναι πολύτιμη σε ένα κλινικό περιβάλλον όπου η διαφάνεια είναι ζωτικής σημασίας. Ωστόσο, ενδέχεται να είναι επιρρεπή σε υπερπροσαρμογή, ιδίως παρουσία θορυβωδών δεδομένων.
- Λογιστική παλινδρόμηση (LR): Ένα απλό μοντέλο που είναι αποτελεσματικό όταν η σχέση μεταξύ των χαρακτηριστικών και της μεταβλητής-στόχου είναι περίπου γραμμική. Η απλότητά του επιτρέπει τη γρήγορη εκπαίδευση και ανάπτυξη, αλλά ενδέχεται να μην καταγράφει πολύπλοκες αλληλεπιδράσεις μεταξύ των μεταβλητών.
- Μηχανές διανυσμάτων υποστήριξης (SVM): Αυτά τα μοντέλα είναι ισχυρά σε χώρους υψηλών διαστάσεων και είναι αποτελεσματικά στην εύρεση ενός υπερεπιπέδου που διαχωρίζει καλύτερα τις διάφορες κλάσεις. Τα SVM μπορούν να χειριστούν καλά τις μη γραμμικές σχέσεις με τη χρήση συναρτήσεων πυρήνα, αλλά απαιτούν προσεκτική ρύθμιση των παραμέτρων, όπως ο όρος κανονικοποίησης και η επιλογή του πυρήνα.
- k-κοντινότεροι γείτονες (kNN): Αυτό το μοντέλο είναι απλό και διαισθητικό, κάνοντας ταξινομήσεις με βάση την πλειοψηφούσα κλάση μεταξύ των πλησιέστερων γειτόνων. Ενώ είναι αποτελεσματικό σε χώρους χαμηλών διαστάσεων, το kNN μπορεί να δυσκολευτεί με μεγάλα σύνολα δεδομένων και χώρους υψηλών διαστάσεων λόγω της κατάρτας της διαστατικότητας.
- Νευρωνικά δίκτυα (NN): Ιδιαίτερα κατάλληλα για τη σύλληψη μη γραμμικών προτύπων σε πολύπλοκα δεδομένα, τα νευρωνικά δίκτυα είναι ιδιαίτερα ευέλικτα και μπορούν να μοντελοποιήσουν περίπλοκες σχέσεις

### 3. Αποτελέσματα και η ερμηνεία τους

Τα αποτελέσματα της μελέτης είναι συναρπαστικά, καθώς δείχνουν ότι τα μοντέλα μηχανικής μάθησης μπορούν να επιτύχουν υψηλή ακρίβεια στη διάκριση μεταξύ κοιλιακών και ραχιαίων νευρικών ριζών. Η αναφερόμενη ακρίβεια έως και 95,90 % όταν χρησιμοποιείται ένας συνδυασμός κατωφλίου και λανθάνουσας κατάστασης ως προγνωστικοί παράγοντες είναι ιδιαίτερα αξιοσημείωτη. Αυτό το επίπεδο ακρίβειας υποδηλώνει ότι αυτά τα μοντέλα μπορούν να βοηθήσουν αξιόπιστα στην αναγνώριση των νευρών κατά τη διάρκεια της SDR, μειώνοντας ενδεχομένως τον κίνδυνο μετεγχειρητικών κινητικών ελλειμμάτων.

- ημασία των νευροφυσιολογικών παραμέτρων: Η μελέτη υπογραμμίζει τη σημασία της χρήσης πολλαπλών νευροφυσιολογικών παραμέτρων για την ενημέρωση των

μοντέλων μηχανικής μάθησης. Οι σημαντικές διαφορές στα κατώφλια και τις λανθάνουσες περιόδους μεταξύ κοιλιακών και ραχιαίων ριζών υποδεικνύουν ότι αυτές οι παράμετροι είναι κρίσιμες για την ακριβή ταξινόμηση. Τα ευρήματα της μελέτης υποστηρίζουν τη χρήση μιας προσέγγισης πολλαπλών παραμέτρων για τη μεγιστοποίηση της ακρίβειας της διεγχειρητικής ταυτοποίησης των νεύρων.

- Επιπτώσεις για τη χειρουργική πρακτική: Η ικανότητα ποσοτικής διάκρισης μεταξύ των τύπων νεύρων κατά τη διάρκεια της χειρουργικής επέμβασης έχει άμεσες επιπτώσεις στη χειρουργική πρακτική. Οι χειρουργοί μπορούν να βασίζονται σε αυτά τα μοντέλα για να λαμβάνουν πιο τεκμηριωμένες αποφάσεις, ιδίως σε πολύπλοκες περιπτώσεις όπου η οπτική αναγνώριση των νεύρων αποτελεί πρόκληση. Αυτό θα μπορούσε να οδηγήσει σε πιο συνεπή αποτελέσματα και σε μείωση της συχνότητας εμφάνισης επιπλοκών που σχετίζονται με τα νεύρα.

#### **1.6.4 Μελέτη 4: Ευκαιρίες και προκλήσεις της επιβλεπόμενης μηχανικής μάθησης για την ταξινόμηση των κινητικών προκλητών δυναμικών ανάλογα με τους μύες**

##### **1. Εισαγωγή και σημασία**

Τα κινητικά προκλητά δυναμικά (MEP) αποτελούν κρίσιμο συστατικό της διεγχειρητικής νευροφυσιολογικής παρακολούθησης (IONM), ιδίως κατά τη διάρκεια χειρουργικών επεμβάσεων που αφορούν τον νωτιαίο μυελό και τον εγκέφαλο. Τα MEP παρέχουν ανατροφοδότηση σε πραγματικό χρόνο σχετικά με τη λειτουργική ακεραιότητα των κινητικών οδών, βοηθώντας τους χειρουργούς να αποφύγουν την πρόκληση βλάβης σε κρίσιμους κινητικούς νευρώνες. Ωστόσο, η ερμηνεία των MEPs είναι ένα πολύπλοκο έργο λόγω της μεταβλητότητας των σημάτων, η οποία μπορεί να επηρεαστεί από μια σειρά παραγόντων, όπως η ανατομία του ασθενούς, οι χειρουργικές διαδικασίες και η τεχνική ρύθμιση του εξοπλισμού παρακολούθησης.

Αυτό το άρθρο διερευνά τις δυνατότητες της επιβλεπόμενης μηχανικής μάθησης (ML) για τη βελτίωση της ταξινόμησης των MEPs ανάλογα με τους μύες από τους οποίους καταγράφονται. Με την αυτοματοποίηση αυτής της ταξινόμησης, η ML θα μπορούσε να μειώσει σημαντικά το γνωστικό φορτίο των νευροφυσιολόγων και να αυξήσει την ακρίβεια της διεγχειρητικής παρακολούθησης, οδηγώντας σε καλύτερα αποτελέσματα για τους ασθενείς(42).

##### **2. Στόχος και ερευνητικοί στόχοι**

Ο πρωταρχικός στόχος της μελέτης είναι η αξιολόγηση της αποτελεσματικότητας των αλγορίθμων ML με επίβλεψη στην ταξινόμηση των MEP με βάση τη μυϊκή ομάδα από την οποία προέρχονται. Το έργο αυτό εκτελείται παραδοσιακά από ανθρώπινους εμπειρογνώμονες, οι οποίοι βασίζονται στην εμπειρία τους και στην κατανόηση των νευροφυσιολογικών προτύπων. Στόχος της μελέτης είναι να προσδιοριστεί κατά πόσον τα τυποποιημένα μοντέλα ML μπορούν να φτάσουν ή να ξεπεράσουν την ανθρώπινη απόδοση σε αυτόν τον τομέα, προσφέροντας έτσι μια αξιόπιστη, αυτοματοποιημένη λύση για την ταξινόμηση των μυών κατά τη διάρκεια χειρουργικών επεμβάσεων.

##### **3. Μεθοδολογία**

Η μελέτη χρησιμοποιεί ένα σύνολο δεδομένων από MEPs που καταγράφηκαν από 36 ασθενείς που υποβλήθηκαν σε νευροχειρουργική επέμβαση. Τα MEPs καταγράφηκαν από διαφορετικές μυϊκές ομάδες, συμπεριλαμβανομένων τόσο των άνω όσο και των κάτω άκρων. Τα βασικά βήματα της μεθοδολογίας περιλαμβάνουν:

- Προεπεξεργασία δεδομένων: Αυτό περιλαμβάνει την ανίχνευση κορυφών και την κανονικοποίηση των σημάτων MEP για την προετοιμασία τους για ανάλυση. Η μελέτη εφαρμόζει επίσης τεχνικές μείωσης της διαστατικότητας, όπως η Ανάλυση Κύριων Συνιστωσών (PCA), για τη διαχείριση της υψηλής διαστατικότητας των δεδομένων.
- Η μελέτη χρησιμοποιεί τρεις διαφορετικούς αλγόριθμους ML: Random Forest (RF), k-Nearest Neighbors (kNN) και Logistic Regression (LogReg). Αυτοί οι αλγόριθμοι επιλέχθηκαν για την ισορροπία μεταξύ πολυπλοκότητας και ερμηνευσιμότητας και για την καθιερωμένη χρήση τους σε παρόμοιες εργασίες ταξινόμησης στη βιοϊατρική έρευνα.
- Εξαγωγή χαρακτηριστικών και μηχανική: Η μελέτη δοκιμάζει την αποτελεσματικότητα αυτών των αλγορίθμων τόσο σε ακατέργαστα όσο και σε επεξεργασμένα με χαρακτηριστικά δεδομένα. Οι τεχνικές εξαγωγής χαρακτηριστικών χρησιμοποιήθηκαν για τη βελτίωση της απόδοσης απλούστερων μοντέλων όπως η λογιστική παλινδρόμηση, τα οποία μπορεί να δυσκολεύονται με ακατέργαστα, υψηλής διάστασης δεδομένα.

#### 4. Αποτελέσματα

Τα αποτελέσματα της μελέτης υποδεικνύουν ότι οι αλγόριθμοι ML με επίβλεψη μπορούν να ταξινομήσουν αποτελεσματικά τα MEP ανάλογα με τους μύες από τους οποίους προέρχονται, με το Random Forest (RF) να παρουσιάζει την υψηλότερη ακρίβεια. Συγκεκριμένα:

- Random Forest (RF): Πέτυχε την υψηλότερη ακρίβεια (97%) στην ταξινόμηση των MEPs από διαφορετικά άκρα, υποδεικνύοντας ότι οι μέθοδοι συνόλου είναι ιδιαίτερα αποτελεσματικές στον χειρισμό της μεταβλητότητας και του θορύβου που ενυπάρχουν στα σήματα MEP.
- k-κοντινότεροι γείτονες (kNN): Η εξάρτηση του kNN από την εγγύτητα το καθιστά ευαίσθητο στο θόρυβο, γεγονός που μπορεί να εξηγήσει την ελαφρώς χαμηλότερη απόδοσή του.
- Λογιστική παλινδρόμηση (LogReg): Βελτιώθηκε σημαντικά με τα δεδομένα με μηχανικά χαρακτηριστικά, αλλά ήταν λιγότερο αποτελεσματική σε ακατέργαστα δεδομένα, υπογραμμίζοντας την ανάγκη προσεκτικής επιλογής χαρακτηριστικών και προεπεξεργασίας όταν χρησιμοποιούνται απλούστερα μοντέλα.

## 2 Μεθοδολογία

Αυτή η ενότητα παρέχει λεπτομερή περιγραφή της μεθοδολογίας που χρησιμοποιήθηκε στην παρούσα μελέτη για την ανάπτυξη και αξιολόγηση μοντέλων μηχανικής μάθησης (ML) για την ενίσχυση της διεγχειρητικής νευροπαρακολούθησης (IONM). Περιλαμβάνει τη συλλογή και την προεπεξεργασία των δεδομένων, την επιλογή και τον συντονισμό των μοντέλων ML και τις τεχνικές επικύρωσης που χρησιμοποιήθηκαν για να διασφαλιστεί η ευρωστία και η αξιοπιστία του μοντέλου.

### 2.1 Περιγραφή των δεδομένων IONM

Τα δεδομένα συλλέχθηκαν από μία έρευνα που (43) περιγράφει τη συλλογή και ανάλυση ενός πολυκαναλικού dataset ηλεκτρομυογραφίας (EMG) που πραγματοποιήθηκε κατά τη διάρκεια χειρουργικών επεμβάσεων στην περιοχή της παρεγκεφαλιδικής γωνίας. Η έρευνα επικεντρώνεται στη χρήση της Συνεχούς Ενδοεγχειρητικής Νευροφυσιολογικής Παρακολούθησης (cIONM) για την προστασία των κρανιακών νεύρων κατά τη διάρκεια των επεμβάσεων, καταγράφοντας τη νευρική δραστηριότητα μέσω σημάτων EMG σε πραγματικό χρόνο.

Τα δεδομένα συλλέχθηκαν από 11 ασθενείς με τη χρήση του συστήματος Neuromaster G1 MEE-2000 της Nihon Kohden, με τη βοήθεια υποδόριων βελονοειδών ηλεκτροδίων. Καταγράφηκαν σήματα από τα κρανιακά νεύρα VII (προσωπικό νεύρο), V (τρίδυμο νεύρο), XI (παραπληρωματικό νεύρο), X (πνευμονογαστρικό νεύρο), και XII (υπογλώσσιο νεύρο). Οι ηλεκτρομυογραφικές καταγραφές έγιναν συνεχώς κατά τη διάρκεια των επεμβάσεων, με το φάσμα συχνοτήτων να ορίζεται μεταξύ 5 Hz και 2 kHz. Οι καταγραφές έγιναν σε 6 κανάλια ταυτόχρονα, με τα δύο πρώτα να καταγράφουν σήματα από το προσωπικό νεύρο και τα υπόλοιπα τέσσερα από τα άλλα κρανιακά νεύρα.

Τα δεδομένα χωρίστηκαν σε τμήματα (segments), ενώ οι καταγραφές επισημάνθηκαν με ετικέτες από ειδικούς νευροφυσιολόγους, με στόχο την κατηγοριοποίηση των σημάτων σε επτά κατηγορίες: A-train, A-train salvo, B-train με αιχμές, B-train με εκρήξεις, προκαλούμενα (evoked) σήματα, artifacts (παρεμβολές), και Quiet (φυσιολογική δραστηριότητα). Κάθε κανάλι καταγραφής αναλογεί σε ένα συγκεκριμένο νεύρο, και τα σήματα αντιστοιχίζονται σε συγκεκριμένες χρονικές περιόδους, επιτρέποντας την πλήρη παρακολούθηση της δραστηριότητας των νεύρων κατά την επέμβαση.

#### Κατηγορίες σημάτων:

Τα ηλεκτρομυογραφήματα ταξινομήθηκαν σε επτά κατηγορίες σύμφωνα με την κλινική τους σημασία:

1. **A-train:** Σήματα υψηλής συχνότητας και χαμηλού πλάτους που δείχνουν πιθανή μόνιμη βλάβη νεύρου.
2. **A-train salvo:** Σύντομες εκρήξεις A-train.
3. **B-train με αιχμές:** Μεμονωμένες αιχμές που εμφανίζονται με κανονικό ή ακανόνιστο ρυθμό.
4. **B-train με εκρήξεις:** Μεμονωμένες εκρήξεις που εμφανίζονται με κανονικό ή ακανόνιστο ρυθμό.
5. **Evoke:** Ηλεκτρικά προκαλούμενες ενέργειες από το νεύρο.
6. **Artifact:** Σήματα που προέρχονται από παρεμβολές εξοπλισμού.

## 7. **Quiet:** Η φυσιολογική βασική δραστηριότητα του EMG.

Η έρευνα επικεντρώνεται στην αξιολόγηση των σημάτων αυτών για την πρόβλεψη μετεγχειρητικών επιπλοκών όπως η πάρεση των κρανιακών νεύρων, ενώ παράλληλα τονίζεται η σημασία της ανάπτυξης αυτόματων συστημάτων ανίχνευσης σημάτων και συναγερμού για την έγκαιρη προειδοποίηση των χειρουργών. Οι εφαρμογές της έρευνας εκτείνονται και στον τομέα της μηχανικής μάθησης, με το dataset να παρέχει σημαντική υποστήριξη στην ανάπτυξη αλγορίθμων αναγνώρισης προτύπων και την αυτοματοποίηση της παρακολούθησης. (44).

Οι επτά διακριτές κατηγορίες συγχωνευτήκαν σε δυο διακριτές ομάδες '0' και '1' όπου το 0 συμβολίζει ήρεμο EMG χωρίς να υποδηλώνεται κάποιος κίνδυνος κατά τη διάρκεια του χειρουργείου ενώ αντίστοιχα το 1 δηλώνει ενόχληση, τραυματισμό κάποιου νεύρου, υπάρχουν 366 τιμές ίσες με 0 και 96 τιμές ίσες με 1.

## 2.2 Εξαγωγή χαρακτηριστικών

Για να κατανοήσουμε τη σημασία των διαφόρων χαρακτηριστικών που χρησιμοποιούνται στην ανάλυση των ηλεκτροφυσιολογικών σημάτων, όπως το ηλεκτρομυογράφημα (EMG), είναι απαραίτητο να εμβαθύνουμε στους τύπους, τους τύπους και τις εξηγήσεις τους. Αυτά τα χαρακτηριστικά μπορούν να κατηγοριοποιηθούν σε χαρακτηριστικά πεδίου χρόνου και πεδίου συχνότητας. Ακολουθεί μια λεπτομερής ανάλυση του καθενός:

### **Χαρακτηριστικά στο πεδίο του χρόνου:**

Η **Μέση Απόλυτη Τιμή** (Mean Absolute Value, MAV) είναι ένα μέτρο που χρησιμοποιείται συχνά για την ανάλυση σημάτων, όπως τα σήματα ηλεκτρομυογραφίας (EMG). Η MAV υπολογίζεται ως ο μέσος όρος των απόλυτων τιμών των δειγμάτων ενός σήματος και παρέχει μια εκτίμηση της ενέργειας του σήματος. Αυτό το μέτρο είναι πολύ χρήσιμο για την εκτίμηση της δραστηριότητας σε ένα σήμα, ιδίως όταν το σήμα μπορεί να περιέχει τόσο θετικές όσο και αρνητικές τιμές

Τύπος:

$$MAV = \frac{1}{N} \sum_{i=0}^N |x_i| \quad (3.1)$$

όπου:

- N είναι ο αριθμός των δειγμάτων του σήματος
- $x_i$  είναι η τιμή του σήματος στο i-οστό δείγμα

Η MAV είναι ιδιαίτερα χρήσιμη σε περιπτώσεις όπου το σήμα έχει θόρυβο ή μεγάλες διακυμάνσεις, καθώς παρέχει έναν τρόπο για να μετρηθεί η μέση ισχύς του σήματος ανεξάρτητα από τη φάση του.

Οι **Μηδενικές Διαβάσεις** (Zero Crossings, ZC) αναφέρονται στο φαινόμενο κατά το οποίο ένα σήμα αλλάζει από θετικές σε αρνητικές τιμές ή το αντίστροφο. Στην ανάλυση σημάτων,



ειδικά στην ηλεκτρομυογραφία (EMG) και άλλες εφαρμογές βιοϊατρικής μηχανικής, οι μηδενικές διαβάσεις είναι σημαντικές καθώς παρέχουν πληροφορίες για τη συχνότητα και τη δραστηριότητα ενός σήματος. Ο αριθμός των μηδενικών διαβάσεων ενός σήματος μπορεί να δώσει πληροφορίες για τη συχνότητα του σήματος ή για την παρουσία θορύβου(45).

Τύπος

$$ZC = \sum_{i=1}^{N-1} 1[(x_i \cdot x_{i+1} < 0) \cap (|x_i - x_{i+1}| \geq \text{Threshold})](3.2)$$

όπου:

- $x_i$  είναι η τιμή του σήματος στο  $i$ -οστό δείγμα,
- $N$  είναι ο αριθμός των δειγμάτων του σήματος

**Χρησιμότητα:**

Οι μηδενικές διαβάσεις χρησιμοποιούνται συχνά ως χαρακτηριστικό στην επεξεργασία σημάτων για την ανάλυση της συχνότητας και τη διάκριση διαφορετικών τύπων σημάτων. Στην ηλεκτρομυογραφία, μπορούν να δείξουν την παρουσία μυϊκής δραστηριότητας ή να βοηθήσουν στη διάκριση μεταξύ διαφορετικών τύπων μυϊκών κινήσεων.

Οι **Αλλαγές Σημείων Κλίσης (Slope Sign Changes, SSC)** είναι ένα χαρακτηριστικό που χρησιμοποιείται συχνά στην ανάλυση σημάτων, ιδιαίτερα στην επεξεργασία βιοϊατρικών σημάτων όπως τα σήματα ηλεκτρομυογραφήματος (EMG). Το SSC μετρά τον αριθμό των αλλαγών στην κλίση του σήματος, δηλαδή πόσες φορές η κλίση (δηλαδή η κατεύθυνση) του σήματος αλλάζει από αύξουσα σε φθίνουσα και το αντίστροφο. Η κλίση ενός σήματος δείχνει αν το σήμα αυξάνεται ή μειώνεται σε μια συγκεκριμένη χρονική στιγμή. Όταν ένα σήμα παρουσιάζει πολλές αλλαγές στην κλίση του, αυτό μπορεί να υποδεικνύει υψηλή συχνότητα δραστηριότητας ή μεταβολές στο σήμα που μπορεί να είναι κρίσιμες για την ανάλυση(46)

Τύπος:

$$SSC = \sum_{i=2}^{N-1} f[(x_i - x_{i-1}) \cdot (x_i - x_{i+1}) > 0 \cap (|x_i - x_{i-1}| \geq \text{Threshold})](3.3)$$

όπου:

- $x_i$  είναι η τιμή του σήματος στο  $i$ -οστό δείγμα,
- Το  $f$  είναι μια συνάρτηση που επιστρέφει 1 αν το γινόμενο  $(x_i - x_{i-1}) \cdot (x_i - x_{i+1})$  είναι αρνητικό, υποδεικνύοντας αλλαγή κλίσης.

**Χρησιμότητα:**

Οι Αλλαγές Σημείων Κλίσης χρησιμοποιούνται για να μετρηθεί η πολυπλοκότητα και η δυναμική ενός σήματος. Στην περίπτωση της ηλεκτρομυογραφίας, μπορεί να βοηθήσει στη διάκριση μεταξύ διαφορετικών τύπων μυϊκής δραστηριότητας, καθώς και στην ανίχνευση της έναρξης ή της διακοπής μιας μυϊκής συστολής.

Το **Μήκος Κυματομορφής (Waveform Length, WL)** είναι ένα χαρακτηριστικό που χρησιμοποιείται συχνά στην ανάλυση σημάτων, ειδικά σε βιοϊατρικά σήματα όπως τα σήματα ηλεκτρομυογραφίας (EMG). Το μήκος κυματομορφής μετρά τη συνολική "διαδρομή" ή το άθροισμα των απολύτων διαφορών μεταξύ διαδοχικών σημείων ενός σήματος. Είναι ένα μέτρο της πολυπλοκότητας και της ενέργειας του σήματος, καθώς μεγαλύτερες τιμές WL υποδηλώνουν περισσότερο δραστήρια ή θορυβώδη σήματα.

Τύπος:

$$WL = \sum_{i=1}^{N-1} |x_{i+1} - x_i| \quad (3.4)$$

όπου:

- N είναι ο αριθμός των δειγμάτων του σήματος
- $x_i$  είναι η τιμή του σήματος στο i-οστό δείγμα

Το WL χρησιμοποιείται συχνά ως χαρακτηριστικό σε εφαρμογές μηχανικής μάθησης, όπου τα σήματα πρέπει να ταξινομηθούν ή να αναλυθούν για τον εντοπισμό συγκεκριμένων μοτίβων ή καταστάσεων, όπως στη διάγνωση νευρολογικών παθήσεων ή στην ανάπτυξη προθετικών συστημάτων που βασίζονται σε EMG.

Η **Τυπική Απόκλιση** είναι ένα στατιστικό μέτρο που χρησιμοποιείται για να προσδιορίσει πόσο διασκορπισμένες ή αποκλίνουσες είναι οι τιμές ενός συνόλου δεδομένων γύρω από τον μέσο όρο (μέση τιμή) του συνόλου. Συγκεκριμένα, η τυπική απόκλιση μετρά τη μέση απόσταση κάθε τιμής του συνόλου από τον μέσο όρο. Είναι ένα κρίσιμο μέτρο στη στατιστική ανάλυση, καθώς παρέχει πληροφορίες σχετικά με την κατανομή των δεδομένων.

Τύπος:

$$SD = \sqrt{\frac{1}{N} \sum_{i=1}^N (x_i - \mu)^2} \quad (3.5)$$

όπου:

- N είναι ο αριθμός των δειγμάτων του σήματος
- $x_i$  είναι η τιμή του σήματος στο i-οστό δείγμα
- $\mu$  είναι η μέση τιμή των δεδομένων.

**Χρησιμότητα:**

- **Μεταβλητότητα:** Η τυπική απόκλιση δείχνει πόσο πολύ αποκλίνουν οι τιμές ενός συνόλου δεδομένων από τη μέση τιμή. Μια μικρή τυπική απόκλιση υποδηλώνει ότι οι τιμές είναι κοντά στη μέση τιμή, ενώ μια μεγάλη τυπική απόκλιση υποδεικνύει ότι οι τιμές είναι διασκορπισμένες μακριά από τη μέση τιμή.
- **Ανάλυση δεδομένων:** Χρησιμοποιείται ευρέως σε κάθε πεδίο που περιλαμβάνει στατιστική ανάλυση, όπως στην οικονομία, την ιατρική, την εκπαίδευση, και άλλες

επιστήμες. Για παράδειγμα, σε μια ιατρική μελέτη, η τυπική απόκλιση μπορεί να βοηθήσει να κατανοηθεί η διακύμανση της αρτηριακής πίεσης μεταξύ διαφορετικών ατόμων.

Η **Ανομοιομορφία (Skewness)** είναι ένα στατιστικό μέτρο που περιγράφει τη συμμετρία ή την ασυμμετρία μιας κατανομής δεδομένων. Πιο συγκεκριμένα, η ανομοιομορφία δείχνει αν τα δεδομένα είναι συμμετρικά κατανεμημένα γύρω από τη μέση τιμή ή αν κλίνουν προς μία πλευρά (αριστερά ή δεξιά)

Τύποι Ανομοιομορφίας:

1. **Θετική Ανομοιομορφία (Positive Skewness):**

- Όταν μια κατανομή έχει θετική ανομοιομορφία, η ουρά της κατανομής είναι πιο μακριά προς τα δεξιά. Αυτό σημαίνει ότι υπάρχουν περισσότερες τιμές κάτω από τη μέση τιμή και λιγότερες τιμές πάνω από αυτήν, με μερικές τιμές να είναι εξαιρετικά υψηλές.
- Παράδειγμα: Η κατανομή των εισοδημάτων σε πολλές χώρες, όπου οι περισσότεροι άνθρωποι έχουν χαμηλά ή μέτρια εισοδήματα, αλλά υπάρχουν λίγοι άνθρωποι με εξαιρετικά υψηλά εισοδήματα.

2. **Αρνητική Ανομοιομορφία (Negative Skewness):**

- Όταν μια κατανομή έχει αρνητική ανομοιομορφία, η ουρά της κατανομής είναι πιο μακριά προς τα αριστερά. Αυτό σημαίνει ότι υπάρχουν περισσότερες τιμές πάνω από τη μέση τιμή και λιγότερες τιμές κάτω από αυτήν, με μερικές τιμές να είναι εξαιρετικά χαμηλές.
- Παράδειγμα: Ο χρόνος ολοκλήρωσης μιας εύκολης εξέτασης, όπου οι περισσότεροι μαθητές τελειώνουν γρήγορα, αλλά μερικοί μπορεί να πάρουν πολύ περισσότερο χρόνο.

3. **Μηδενική Ανομοιομορφία (No Skewness):**

- Μια κατανομή που έχει μηδενική ανομοιομορφία είναι συμμετρική γύρω από τη μέση τιμή της. Στην περίπτωση αυτή, η κατανομή είναι κανονική (καμπύλη Gauss) και η μέση τιμή, η διάμεσος και η επικρατούσα τιμή συμπίπτουν.

Τύπος:

$$\text{Skewness} = \frac{N}{(N-1)(N-2)} \sum_{i=1}^N \left( \frac{x_i - \mu}{SD} \right)^3 \quad (3.6)$$

όπου:

- N είναι ο αριθμός των δεδομένων,
- $x_i$  είναι η τιμή του  $i$ -οστού δεδομένου,
- $\mu$  είναι η μέση τιμή των δεδομένων,
- SD είναι η τυπική απόκλιση.

**Χρησιμότητα:**

- **Κατανόηση Κατανομών:** Η ανομοιομορφία βοηθάει στην κατανόηση του σχήματος της κατανομής των δεδομένων και αν αυτή η κατανομή είναι συμμετρική ή όχι.
- **Ανάλυση Δεδομένων:** Στη στατιστική ανάλυση, η ανομοιομορφία χρησιμοποιείται για να εντοπίσει ασυμμετρίες που μπορεί να υποδεικνύουν την παρουσία εξαιρετικά υψηλών ή χαμηλών τιμών (outliers).

Εφαρμογές:

Η ανομοιομορφία είναι ένα σημαντικό εργαλείο σε πολλούς τομείς, όπως τα οικονομικά, η βιοστατιστική και η κοινωνιολογία, όπου η κατανόηση της κατανομής των δεδομένων είναι κρίσιμη για την εξαγωγή συμπερασμάτων και τη λήψη αποφάσεων.

Η **Κύρτωση (Kurtosis)** είναι ένα στατιστικό μέτρο που περιγράφει την "αιχμηρότητα" ή την "ουρά" μιας κατανομής σε σχέση με μια κανονική κατανομή. Η κύρτωση δείχνει πόσο συχνά εμφανίζονται ακραίες τιμές (τιμές στις ουρές της κατανομής) σε σχέση με τη μέση τιμή(47).

Είδη Κύρτωσης:

1. **Υπέρκυρτη κατανομή (Leptokurtic):**
  - Όταν η κύρτωση είναι θετική (kurtosis > 0), η κατανομή έχει πιο "αιχμηρή" κορυφή και πιο βαριές ουρές σε σχέση με την κανονική κατανομή. Αυτό σημαίνει ότι υπάρχουν περισσότερες ακραίες τιμές.
  - Παράδειγμα: Η απόδοση ενός επενδυτικού χαρτοφυλακίου που μπορεί να έχει μεγάλες αυξομειώσεις.
2. **Μέσοκυρτη κατανομή (Mesokurtic):**
  - Όταν η κύρτωση είναι μηδενική (kurtosis = 0), η κατανομή έχει την ίδια μορφή με την κανονική κατανομή. Αυτό είναι τυπικά το σχήμα της καμπύλης Gauss.
  - Παράδειγμα: Στην περίπτωση μιας κανονικής κατανομής, όπως οι μετρήσεις ύψους σε έναν πληθυσμό.
3. **Υποκυρτή κατανομή (Platykurtic):**
  - Όταν η κύρτωση είναι αρνητική (kurtosis < 0), η κατανομή είναι πιο "επίπεδη" και έχει λιγότερες ακραίες τιμές σε σχέση με την κανονική κατανομή. Οι ουρές της κατανομής είναι πιο λεπτές.
  - Παράδειγμα: Τα δεδομένα που δείχνουν μικρότερη μεταβλητότητα από αυτήν που περιμένουμε, όπως τα δεδομένα θερμοκρασίας σε ένα περιβάλλον με κλιματισμό.

Τύπος

$$\text{Kurtosis} = \frac{N(N+1)}{(N-1)(N-2)(N-3)} \sum_{i=1}^N \left( \frac{x_i - \mu}{SD} \right)^4 - \frac{3(N-1)^2}{(N-2)(N-3)} \quad (3.7)$$

όπου:

- N είναι ο αριθμός των δεδομένων,
- $x_i$  είναι η τιμή του  $i$ -οστού δεδομένου,
- $\mu$  είναι η μέση τιμή των δεδομένων,

- SD είναι η τυπική απόκλιση.

### **Χαρακτηριστικά στο πεδίο της συχνότητας**

Η **Εντροπία Shannon** είναι ένα μέτρο από τη θεωρία πληροφορίας που χρησιμοποιείται για να ποσοτικοποιήσει την αβεβαιότητα ή την τυχαιότητα σε ένα σύνολο δεδομένων. Εισήχθη από τον Claude Shannon το 1948 στο πλαίσιο της θεωρίας πληροφορίας και αποτελεί βασικό εργαλείο για την κατανόηση και τη μέτρηση της πληροφορίας σε ένα σήμα ή ένα σύστημα(48).

Ορισμός:

Η Εντροπία Shannon υπολογίζεται με βάση την πιθανότητα εμφάνισης των διαφόρων συμβόλων ή τιμών σε ένα σύνολο δεδομένων. Αν έχουμε ένα σύνολο από πιθανά γεγονότα (ή σύμβολα) και γνωρίζουμε τις πιθανότητες εμφάνισής τους, η εντροπία τους μπορεί να υπολογιστεί ως εξής:

Τύπος:

$$H = - \sum_{i=1}^N p(x_i) \log p(x_i) (3.8)$$

όπου:

- $p(x_i)$  είναι η πιθανότητα εμφάνισης του γεγονότος ή της τιμής  $(x_i)$
- $N$  είναι ο αριθμός των διαφορετικών γεγονότων ή τιμών που μπορεί να πάρει

**Χρησιμότητα:**

- **Μέτρο Τυχαιότητας:** Η Εντροπία Shannon παρέχει μια ποσοτική εκτίμηση του βαθμού αβεβαιότητας ή τυχαιότητας σε ένα σύστημα. Αν όλες οι πιθανότητες είναι ίσες, η εντροπία είναι υψηλή, ενώ αν ένα γεγονός είναι πολύ πιο πιθανό από τα άλλα, η εντροπία είναι χαμηλή.
- **Συμπύεση Δεδομένων:** Στη συμπίεση δεδομένων, η εντροπία χρησιμοποιείται για να καθοριστεί το κατώτατο όριο της ποσότητας πληροφορίας που απαιτείται για την αναπαράσταση των δεδομένων χωρίς απώλεια.
- **Ανάλυση Πληροφορίας:** Σε εφαρμογές όπως η ανάλυση σημάτων ή η βιοπληροφορική, η Εντροπία Shannon μπορεί να χρησιμοποιηθεί για να κατανοηθεί η πολυπλοκότητα ή η τυχαιότητα ενός σήματος.

Η **Φασματική Εντροπία (Spectral Entropy)** είναι ένα μέτρο της τυχαιότητας ή της αταξίας ενός σήματος στο φασματικό πεδίο, δηλαδή αφού το σήμα έχει μετατραπεί από το χρονικό πεδίο στο πεδίο των συχνοτήτων μέσω μιας φασματικής ανάλυσης, όπως ο Μετασχηματισμός Fourier. Η Φασματική Εντροπία υπολογίζει την εντροπία των φασματικών συνιστωσών ενός σήματος και μπορεί να χρησιμοποιηθεί για να ποσοτικοποιήσει την πολυπλοκότητα του σήματος στις διάφορες συχνότητες.

Η Φασματική Εντροπία είναι παρόμοια με την Εντροπία Shannon, αλλά εφαρμόζεται στο φάσμα συχνοτήτων ενός σήματος αντί για το χρονικό του πεδίο. Αν ένα σήμα έχει ομοιόμορφα κατανομημένη ενέργεια σε πολλές συχνότητες, η Φασματική Εντροπία του θα είναι υψηλή, υποδεικνύοντας υψηλή πολυπλοκότητα ή τυχαιότητα. Αντίθετα, αν η ενέργεια συγκεντρώνεται σε λίγες συχνότητες, η Φασματική Εντροπία θα είναι χαμηλή(49).

Τύπος

$$H_s = - \sum_{i=1}^M P(f_i) \log P(f_i) \quad (3.9)$$

όπου:

- $P(f_i)$  είναι η πιθανότητα ή η κανονικοποιημένη ισχύς στη συχνότητα  $f_i$
- $N$  είναι ο αριθμός των συχνοτήτων που εξετάζονται.

**Χρησιμότητα:**

- **Ανάλυση Σημάτων EEG/EMG:** Χρησιμοποιείται ευρέως στην ανάλυση σημάτων EEG και EMG για την αξιολόγηση της πολυπλοκότητας των εγκεφαλικών ή μυϊκών σημάτων και για την ανίχνευση παθολογικών καταστάσεων.
- **Ανίχνευση Γεγονότων:** Μπορεί να χρησιμοποιηθεί για την ανίχνευση σημαντικών γεγονότων, όπως οι κρίσεις επιληψίας ή άλλες νευρολογικές ανωμαλίες, όπου η πολυπλοκότητα του σήματος αλλάζει απότομα.
- **Μηχανική Μάθηση και Εξόρυξη Δεδομένων:** Χρησιμοποιείται ως χαρακτηριστικό σε αλγορίθμους μηχανικής μάθησης για την ταξινόμηση σημάτων με βάση την πολυπλοκότητα και την αταξία τους.

```
def zero_crossings(signal):  
    return ((signal[:-1] * signal[1:]) < 0).sum()  
  
def slope_sign_changes(signal, threshold=0.001):  
    return ((signal[:-2] < signal[1:-1]) & (signal[1:-1] > signal[2:])) |  
    (signal[:-2] > signal[1:-1]) & (signal[1:-1] < signal[2:])).sum()  
  
def waveform_length(signal):  
    return np.sum(np.abs(np.diff(signal)))  
  
def shannon_entropy(signal):  
    hist, _ = np.histogram(signal, bins=64, density=True)  
    return entropy(hist)
```

Ο ΡΟΛΟΣ ΤΗΣ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ ΣΤΗΝ ΠΡΟΒΛΕΨΗ ΝΕΥΡΟΛΟΓΙΚΩΝ ΑΠΟΤΕΛΕΣΜΑΤΩΝ ΑΠΟ  
ΔΕΔΟΜΕΝΑ ΕΝΔΟΕΓΧΕΙΡΗΤΙΚΗΣ ΝΕΥΡΟΠΑΡΑΚΟΛΟΥΘΗΣΗΣ

```
def spectral_entropy(signal, sf=1000):
    freqs, psd = welch(signal, sf)
    psd /= psd.sum() # Normalize the power spectrum
    return entropy(psd)

# Load the CSV file
latest_data_path = '/content/11.csv'
latest_data = pd.read_csv(latest_data_path)

# Drop unnecessary label columns and rename the timestamp column
latest_data_clean = latest_data.drop(columns=['VII_label', 'VII.1_label',
'V_label', 'XI_label', 'X_label', 'XII_label', 'label'])
latest_data_clean.rename(columns={'Unnamed: 0': 'timestamp'},
inplace=True)

# Calculate features for each segment and channel
features_list = []

for segment_name, group in latest_data_clean.groupby('segment_id'):
    features = {
        'segment_id': segment_name,
        'patient_id': group['patient_id'].iloc[0]
    }
    for channel in ['VII', 'VII.1', 'V', 'XI', 'X', 'XII']:
        signal = group[channel].values
        features[f'{channel}_Mean_Abs_Value'] = np.mean(np.abs(signal))
        features[f'{channel}_Zero_Crossings'] = zero_crossings(signal)
        features[f'{channel}_Slope_Sign_Changes'] =
slope_sign_changes(signal)
        features[f'{channel}_Waveform_Length'] = waveform_length(signal)
        features[f'{channel}_Std_Dev'] = np.std(signal)
        features[f'{channel}_Skewness'] = skew(signal)
        features[f'{channel}_Kurtosis'] = kurtosis(signal)
        features[f'{channel}_Shannon_Entropy'] = shannon_entropy(signal)
```

```
features[f'{channel}_Spectral_Entropy'] = spectral_entropy(signal)
features_list.append(features)

# Convert features to DataFrame and save to CSV
features_df = pd.DataFrame(features_list)
features_df.to_csv('/content/untitled', index=False)
```

Αυτός ο κώδικας εκτελεί μια σειρά από βήματα για την επεξεργασία σημάτων και την εξαγωγή χαρακτηριστικών από αυτά. Αρχικά, φορτώνει τα δεδομένα από ένα αρχείο CSV χρησιμοποιώντας τη βιβλιοθήκη `pandas`. Τα δεδομένα περιέχουν σήματα από διαφορετικά κανάλια (όπως VII, VII.1, V, κ.λπ.) καθώς και άλλες πιθανές πληροφορίες, και αποθηκεύονται σε ένα `DataFrame`. Στη συνέχεια, γίνεται προκαταρκτική επεξεργασία, όπου αφαιρούνται οι στήλες που δεν είναι απαραίτητες για την εξαγωγή των χαρακτηριστικών (όπως οι ετικέτες `VII_label`, `VII.1_label`, κ.λπ.), ενώ η στήλη που περιέχει το χρονικό σημείο (`timestamp`) μετονομάζεται σε `timestamp`.

Τα δεδομένα ομαδοποιούνται βάσει της στήλης `segment_id`, η οποία πιθανότατα αντιπροσωπεύει διαφορετικά τμήματα δεδομένων από τον κάθε ασθενή. Για κάθε τμήμα δεδομένων και για κάθε κανάλι (π.χ., VII, VII.1, V), εξάγονται διάφορα χαρακτηριστικά. Αφού εξάγονται όλα τα παραπάνω χαρακτηριστικά για κάθε τμήμα και κανάλι, τα αποτελέσματα αποθηκεύονται σε μία λίστα, η οποία στη συνέχεια μετατρέπεται σε `DataFrame`. Το `DataFrame` αυτό περιέχει όλα τα εξαγόμενα χαρακτηριστικά και αποθηκεύεται σε ένα νέο αρχείο CSV, ώστε να μπορεί να χρησιμοποιηθεί για περαιτέρω ανάλυση ή επεξεργασία, όπως σε μοντέλα μηχανικής μάθησης για ταξινόμηση ή πρόβλεψη.

### 2.3 Εξισορρόπηση Δεδομένων

Η συνάρτηση `scale_dataset` εκτελεί δύο βασικές λειτουργίες που είναι απαραίτητες για την προεπεξεργασία δεδομένων πριν την εφαρμογή αλγορίθμων μηχανικής μάθησης: την κλιμάκωση των χαρακτηριστικών και, εάν ζητηθεί, την εξισορρόπηση των κατηγοριών με `oversampling`. Η λειτουργία της συνάρτησης εξηγείται λεπτομερώς παρακάτω.

Αρχικά, η συνάρτηση λαμβάνει ως είσοδο ένα `DataFrame`, το οποίο περιέχει χαρακτηριστικά και την τελευταία στήλη που αντιπροσωπεύει τη μεταβλητή στόχο. Επιπλέον, υπάρχει η παράμετρος `oversample`, η οποία εάν έχει την τιμή `True`, ενεργοποιεί τη διαδικασία του `oversampling`.

Το πρώτο βήμα της συνάρτησης είναι να διαχωρίσει τα χαρακτηριστικά από τη μεταβλητή στόχο. Αυτό γίνεται με τη χρήση των παρακάτω εντολών:

```
x = dataframe[dataframe.columns[:-1]].values
y = dataframe[dataframe.columns[-1]].values
```

Το `x` περιέχει όλες τις στήλες του `DataFrame` εκτός από την τελευταία, που είναι η μεταβλητή στόχος, ενώ το `y` περιέχει τις τιμές της τελευταίας στήλης, δηλαδή της μεταβλητής στόχου. Η χρήση της μεθόδου `.values` μετατρέπει τα δεδομένα σε πίνακες `NumPy`, οι οποίοι είναι κατάλληλοι για εισαγωγή σε αλγορίθμους μηχανικής μάθησης.



Το δεύτερο βήμα είναι η κλιμάκωση των χαρακτηριστικών με τη βοήθεια του μετασχηματιστή `StandardScaler` από τη βιβλιοθήκη `sklearn`. Η κλιμάκωση είναι σημαντική διότι τα χαρακτηριστικά μπορεί να έχουν διαφορετικές κλίμακες και μονάδες μέτρησης, κάτι που θα μπορούσε να επηρεάσει αρνητικά την απόδοση αλγορίθμων όπως ο KNN, οι οποίοι βασίζονται στις αποστάσεις μεταξύ των δειγμάτων. Ο `StandardScaler` μετατρέπει τα δεδομένα έτσι ώστε να έχουν μέση τιμή 0 και τυπική απόκλιση 1:

```
scaler = StandardScaler()  
x = scaler.fit_transform(x)
```

Η μέθοδος `fit_transform` αρχικά "εκπαιδεύεται" με τα δεδομένα ('fit') και στη συνέχεια τα μετασχηματίζει (`transform`) σύμφωνα με τους κανόνες της τυποποίησης, ώστε κάθε χαρακτηριστικό να έχει την ίδια κλίμακα.

Εάν έχει ζητηθεί εξισορρόπηση κατηγοριών μέσω της παραμέτρου `oversample=True`, τότε εφαρμόζεται το `Random OverSampling`. Αυτό γίνεται για την αντιμετώπιση περιπτώσεων ανισορροπίας στις κατηγορίες της μεταβλητής στόχου. Σε περιπτώσεις όπου ορισμένες κατηγορίες έχουν πολύ λιγότερα παραδείγματα από άλλες, ο αλγόριθμος ενδέχεται να μην αποδίδει καλά, δίνοντας μεγαλύτερη βαρύτητα στις κατηγορίες που εμφανίζονται συχνότερα. Η τεχνική `RandomOverSampler` αντιγράφει παραδείγματα των υποεκπροσωπούμενων κατηγοριών, εξισορροπώντας έτσι την κατανομή:

```
if oversample:  
    ros = RandomOverSampler(random_state=42)  
    x, y = ros.fit_resample(x, y)
```

Η παράμετρος `random_state=42` εξασφαλίζει ότι το αποτέλεσμα της επεξεργασίας θα είναι το ίδιο κάθε φορά που εκτελείται το πρόγραμμα, καθιστώντας τη διαδικασία αναπαραγώγιμη.

Στο τέλος, η συνάρτηση επιστρέφει τα κλιμακωμένα χαρακτηριστικά  $x$  και τις τιμές της μεταβλητής στόχου  $y$ . Αν έχει εφαρμοστεί `oversampling`, τότε οι κατηγορίες είναι πλέον εξισορροπημένες και περιέχουν ισάριθμα παραδείγματα.

Η συνάρτηση `scale_dataset` είναι πολύ χρήσιμη για την προετοιμασία δεδομένων πριν την εφαρμογή αλγορίθμων μηχανικής μάθησης, καθώς:

1. Διασφαλίζει ότι όλα τα χαρακτηριστικά βρίσκονται στην ίδια κλίμακα μέσω της κλιμάκωσης.
2. Εξισορροπεί τις κατηγορίες στην περίπτωση που υπάρχει ανισορροπία, αποτρέποντας τον αλγόριθμο από το να υπερεκπροσωπεί την πλειοψηφική κατηγορία.

Με αυτόν τον τρόπο, το μοντέλο έχει τη δυνατότητα να εκπαιδευτεί καλύτερα και να αποδώσει πιο αξιόπιστα αποτελέσματα, τόσο σε αλγόριθμους που επηρεάζονται από την κλίμακα όσο και σε περιπτώσεις όπου οι κατηγορίες είναι άνισα κατανομημένες.

## 2.4 Επιλογή Χαρακτηριστικών

Η επιλογή χαρακτηριστικών είναι η διαδικασία εντοπισμού και επιλογής ενός υποσυνόλου σχετικών χαρακτηριστικών (μεταβλητών, προβλεπτικών παραγόντων) από ένα μεγαλύτερο σύνολο χαρακτηριστικών για χρήση στην κατασκευή μοντέλων. Αποσκοπεί στην επιλογή των χαρακτηριστικών που είναι πιο χρήσιμα για το μοντέλο πρόβλεψης, ενώ απορρίπτει εκείνα που είναι περιττά, άσχετα ή θορυβώδη.

### **ANOVA F-test**

Στη περίπτωση μας έγινε η χρήση της F-test της ANOVA. Ο έλεγχος F-test της ANOVA (ανάλυση διακύμανσης) είναι μια στατιστική μέθοδος που χρησιμοποιείται για να προσδιοριστεί εάν υπάρχουν σημαντικές διαφορές μεταξύ των μέσων όρων τριών ή περισσότερων ομάδων. Είναι ιδιαίτερα χρήσιμη στην επιλογή χαρακτηριστικών για τη μηχανική μάθηση και τη στατιστική μοντελοποίηση, όπου βοηθά στον εντοπισμό χαρακτηριστικών που έχουν σημαντικές σχέσεις με τη μεταβλητή-στόχο(50).

```
selector = SelectKBest(f_classif, k=3)
x_train_best = selector.fit_transform(x_train, y_train)
x_valid_best = selector.transform(x_valid)
x_test_best = selector.transform(x_test)
selected_features = selector.get_support(indices=True)
best_features = df.columns[selected_features]
```

Αυτό το κομμάτι του κώδικα αφορά την επιλογή χαρακτηριστικών (feature selection) χρησιμοποιώντας τον στατιστικό έλεγχο ANOVA F-test μέσω του εργαλείου SelectKBest από τη βιβλιοθήκη sklearn. Ακολουθεί αναλυτική περιγραφή της λειτουργίας:

Αρχικά, χρησιμοποιείται η συνάρτηση SelectKBest με το κριτήριο επιλογής f\_classif, το οποίο βασίζεται στο ANOVA F-test. Το ANOVA F-test υπολογίζει τη σχέση μεταξύ κάθε χαρακτηριστικού και της μεταβλητής στόχου, και επιλέγει τα χαρακτηριστικά που έχουν τη μεγαλύτερη στατιστική σημασία. Στην περίπτωση αυτή, ορίζεται η παράμετρος k=3, που σημαίνει ότι επιλέγονται τα τρία (3) καλύτερα χαρακτηριστικά, στη συνέχεια θα το αλλάξουμε από το 1-9 για όλους τους συνδιασμούς.

Στη συνέχεια, η εντολή fit\_transform εφαρμόζεται στα δεδομένα εκπαίδευσης (x\_train, y\_train), η οποία αρχικά "εκπαιδεύεται" πάνω στα δεδομένα εκπαίδευσης (δηλαδή υπολογίζει ποιες μεταβλητές είναι οι πιο σημαντικές) και έπειτα μετασχηματίζει το σύνολο εκπαίδευσης, διατηρώντας μόνο τα 3 καλύτερα χαρακτηριστικά. Τα δεδομένα εκπαίδευσης με τα επιλεγμένα χαρακτηριστικά αποθηκεύονται στη μεταβλητή x\_train\_best.

Μετά τον μετασχηματισμό των δεδομένων εκπαίδευσης, η ίδια διαδικασία εφαρμόζεται και στα σύνολα επικύρωσης (x\_valid) και δοκιμών (x\_test), χρησιμοποιώντας την εντολή `transform`. Ωστόσο, σε αυτή την περίπτωση, η διαδικασία απλώς μετασχηματίζει τα δεδομένα διατηρώντας μόνο τα χαρακτηριστικά που είχαν επιλεγεί από το σύνολο

εκπαίδευσης, χωρίς να επανεκπαιδεύεται ο επιλογέας χαρακτηριστικών. Τα δεδομένα επικύρωσης και δοκιμών που προέκυψαν μετά τον μετασχηματισμό αποθηκεύονται στις μεταβλητές `x_valid_best` και `x_test_best`, αντίστοιχα.

Στη συνέχεια, η εντολή `get_support(indices=True)` επιστρέφει τους δείκτες (`index`) των επιλεγμένων χαρακτηριστικών, που υποδεικνύουν ποιες στήλες του αρχικού `DataFrame` περιλαμβάνονται στα επιλεγμένα χαρακτηριστικά. Αυτοί οι δείκτες αποθηκεύονται στη μεταβλητή `selected_features`. Τέλος, χρησιμοποιώντας αυτούς τους δείκτες, ανακτώνται οι ονομασίες των επιλεγμένων χαρακτηριστικών από το αρχικό `DataFrame` `df` και αποθηκεύονται στη μεταβλητή `best_features`.

Με αυτή τη διαδικασία, επιτυγχάνεται η μείωση της διάστασης των δεδομένων, καθώς διατηρούνται μόνο τα πιο σημαντικά χαρακτηριστικά, γεγονός που μπορεί να βελτιώσει την αποδοτικότητα και την απόδοση του μοντέλου μηχανικής μάθησης.

## 2.5 Υπερπαράμετροι

Ορισμός:

Είναι η διαδικασία βελτιστοποίησης των παραμέτρων που διέπουν τη συμπεριφορά ενός μοντέλου μηχανικής μάθησης. Αυτές οι παράμετροι, γνωστές ως υπερπαράμετροι, δεν μαθαίνονται από τα δεδομένα, αλλά καθορίζονται πριν από τη διαδικασία εκπαίδευσης. Παίζουν καθοριστικό ρόλο στην απόδοση του μοντέλου και περιλαμβάνουν πτυχές όπως ο ρυθμός μάθησης, ο αριθμός των κρυφών στρωμάτων σε ένα νευρωνικό δίκτυο, ο αριθμός των γειτόνων στους K-Nearest Neighbors (KNN) και η ισχύς της κανονικοποίησης στη λογιστική παλινδρόμηση.

### 2.5.1 Επιλογή Παραμέτρων για KNN

```
param_grid = {
    'n_neighbors': [3, 5, 7, 9],
    'weights': ['uniform', 'distance'],
    'metric': ['euclidean', 'manhattan']
}
```

Αυτό το κομμάτι του κώδικα ορίζει το πλέγμα παραμέτρων για τον αλγόριθμο K-Nearest Neighbors (KNN), το οποίο θα χρησιμοποιηθεί σε μια διαδικασία Grid Search για την εύρεση του βέλτιστου συνδυασμού παραμέτρων. Το πλέγμα περιλαμβάνει τρεις βασικές παραμέτρους: τον αριθμό των γειτόνων (`n_neighbors`), τον τύπο των βαρών (`weights`), και τη μετρική απόστασης (`metric`).

Πιο συγκεκριμένα, η παράμετρος `n_neighbors` δοκιμάζει τέσσερις διαφορετικές τιμές (3, 5, 7, και 9), που καθορίζουν τον αριθμό των γειτόνων που θα χρησιμοποιήσει ο αλγόριθμος για την ταξινόμηση ενός νέου δείγματος. Αυτή η τιμή επηρεάζει τον τρόπο με τον οποίο ο KNN υπολογίζει τις αποστάσεις και ποια κατηγορία θα επιλέξει για την ταξινόμηση.

Η παράμετρος `weights` καθορίζει αν όλοι οι γείτονες θα έχουν ίσο βάρος (`uniform`) ή αν οι πιο κοντινοί γείτονες θα έχουν μεγαλύτερη βαρύτητα από τους πιο απομακρυσμένους (`distance`). Η επιλογή βαρών μπορεί να επηρεάσει τον τρόπο με τον οποίο ο αλγόριθμος λαμβάνει υπόψη τους γείτονες κατά την ταξινόμηση.

Τέλος, η παράμετρος *metric* καθορίζει τη μετρική απόσταση που θα χρησιμοποιηθεί για τη μέτρηση των αποστάσεων μεταξύ των δειγμάτων. Δοκιμάζονται δύο διαφορετικές μετρικές: η ευκλείδεια απόσταση (*euclidean*), που είναι η συνήθης γεωμετρική απόσταση, και η απόσταση *Manhattan* (*manhattan*), η οποία μετρά την απόσταση λαμβάνοντας υπόψη τη διαδρομή κατά μήκος των αξόνων.

Η διαδικασία *Grid Search* χρησιμοποιεί το πλέγμα παραμέτρων για να δοκιμάσει όλους τους δυνατούς συνδυασμούς των τιμών και να βρει τον βέλτιστο συνδυασμό που οδηγεί στη μέγιστη απόδοση του μοντέλου. Η βελτιστοποίηση των παραμέτρων αυτών είναι κρίσιμη για τη σωστή ρύθμιση του αλγορίθμου *KNN* και για τη βελτίωση της απόδοσής του σε συγκεκριμένα δεδομένα.

### 2.5.2 Επιλογή Παραμέτρων για SVM

```
# Define parameter grid for SVM
param_grid = {
    'C': [0.1, 1, 10],
    'kernel': ['linear', 'rbf'],
    'gamma': ['scale', 'auto']
}
```

Αυτό το κομμάτι κώδικα ορίζει το πλέγμα παραμέτρων που θα χρησιμοποιηθεί για τη βελτιστοποίηση ενός μοντέλου *Support Vector Machine* (*SVM*) μέσω της διαδικασίας *Grid Search*. Το πλέγμα παραμέτρων περιλαμβάνει τις διαφορετικές τιμές που θα δοκιμαστούν για κάθε υπερπαραμέτρο του *SVM*, προκειμένου να βρεθεί ο συνδυασμός που μεγιστοποιεί την απόδοση του μοντέλου.

Οι υπερπαραμέτροι που ορίζονται στο πλέγμα είναι οι εξής:

1. *C*: Η παράμετρος *C* ελέγχει το βαθμό κανονικοποίησης του μοντέλου. Μικρές τιμές της *C* ενισχύουν την απλότητα του μοντέλου, ενώ μεγαλύτερες τιμές επιτρέπουν στο μοντέλο να αποδίδει περισσότερη σημασία στη σωστή ταξινόμηση των δειγμάτων του εκπαιδευτικού συνόλου. Το πλέγμα περιλαμβάνει τρεις τιμές: [0.1, 1, 10], που αντιπροσωπεύουν διαφορετικούς βαθμούς κανονικοποίησης.
2. *kernel*: Η παράμετρος *kernel* καθορίζει τη λειτουργία του *SVM* για τον διαχωρισμό των δεδομένων. Δοκιμάζονται δύο διαφορετικοί τύποι *kernels*:
  - *linear*: Για την εφαρμογή γραμμικού διαχωρισμού των δεδομένων.
  - *rbf*: Για την εφαρμογή του μη γραμμικού *Radial Basis Function* (*RBF*) *kernel*, που επιτρέπει την εκμάθηση πιο περίπλοκων διαχωριστικών συνόρων.
3. *gamma*: Η παράμετρος *gamma* καθορίζει πόση επιρροή έχουν οι μεμονωμένες εκπαιδευτικές περιπτώσεις στον ταξινομητή. Όσο μεγαλύτερη είναι η τιμή του *gamma*, τόσο πιο κοντά στο δείγμα βρίσκονται οι γειτονικές περιοχές που επηρεάζονται από αυτό. Στο πλέγμα παραμέτρων δοκιμάζονται οι τιμές:
  - *scale*: Αυτόματη ρύθμιση του *gamma* με βάση τα χαρακτηριστικά.
  - *auto*: Αυτόματη ρύθμιση του *gamma* χωρίς να λαμβάνεται υπόψη η κλίμακα των χαρακτηριστικών.

Το πλέγμα αυτό χρησιμοποιείται στη διαδικασία Grid Search για να δοκιμαστούν όλοι οι δυνατοί συνδυασμοί των παραπάνω παραμέτρων. Σκοπός είναι να βρεθεί ο καλύτερος συνδυασμός που μεγιστοποιεί την απόδοση του μοντέλου, π.χ., με βάση την ακρίβεια ή άλλη μετρική απόδοσης. Το GridSearchCV θα εκπαιδεύσει το μοντέλο με κάθε δυνατό συνδυασμό παραμέτρων, χρησιμοποιώντας διασταυρούμενη επικύρωση για να αξιολογήσει την απόδοση, και θα επιλέξει τον συνδυασμό που αποδίδει καλύτερα.

### 2.5.3 Επιλογή Παραμέτρων για Logistic Regression

```
# Define parameter grid for Logistic Regression
param_grid = {
    'penalty': ['l1', 'l2', 'elasticnet', 'none'],
    'C': [0.01, 0.1, 1, 10, 100],
    'solver': ['newton-cg', 'lbfgs', 'liblinear', 'sag', 'saga'],
    'max_iter': [100, 200, 300]
}
```

Αυτό το κομμάτι κώδικα ορίζει το πλέγμα παραμέτρων για τη βελτιστοποίηση του μοντέλου Logistic Regression μέσω της διαδικασίας Grid Search. Το πλέγμα περιλαμβάνει διαφορετικές τιμές για τις βασικές υπερπαραμέτρους της λογιστικής παλινδρόμησης (Logistic Regression), με στόχο να βρεθεί ο συνδυασμός που θα μεγιστοποιήσει την απόδοση του μοντέλου.

Οι υπερπαραμέτροι που δοκιμάζονται είναι οι εξής:

1. **penalty**: Αυτή η παράμετρος καθορίζει το είδος της κανονικοποίησης που θα εφαρμοστεί στο μοντέλο για να αποφευχθεί η υπερεκπαίδευση (overfitting). Το πλέγμα περιλαμβάνει τέσσερις επιλογές:
  - 'l1': Κανονικοποίηση L1 (Lasso), η οποία εφαρμόζει απόλυτη τιμή (absolute value) στους συντελεστές.
  - 'l2': Κανονικοποίηση L2 (Ridge), η οποία εφαρμόζει τετράγωνο στους συντελεστές.
  - 'elasticnet': Συνδυασμός της L1 και της L2 κανονικοποίησης.
  - 'none': Καμία κανονικοποίηση.
2. **C**: Η παράμετρος C καθορίζει την ισχύ της κανονικοποίησης. Μεγαλύτερες τιμές της C μειώνουν την κανονικοποίηση, ενώ μικρότερες τιμές ενισχύουν την κανονικοποίηση. Οι τιμές που δοκιμάζονται είναι [0.01, 0.1, 1, 10, 100], που καλύπτουν ένα ευρύ φάσμα επιπέδων κανονικοποίησης.
3. **solver**: Αυτή η παράμετρος καθορίζει τον αλγόριθμο βελτιστοποίησης που θα χρησιμοποιηθεί για την εκπαίδευση του μοντέλου. Δοκιμάζονται οι εξής αλγόριθμοι:

- 'newton-cg': Χρησιμοποιεί τη μέθοδο του Newton για τη βελτιστοποίηση.
  - 'lbfgs': Ένας αλγόριθμος που εφαρμόζει την προσεγγιστική μέθοδο του Broyden-Fletcher-Goldfarb-Shanno.
  - 'liblinear': Χρησιμοποιεί τη μέθοδο liblinear για την ταξινόμηση μικρών συνόλων δεδομένων.
  - 'sag': Η μέθοδος Stochastic Average Gradient, κατάλληλη για μεγάλα datasets.
    - a. 'saga': Μια βελτιωμένη έκδοχή του sag, που υποστηρίζει και τις κανονικοποιήσεις L1 και elasticnet.
4. max\_iter: Αυτή η παράμετρος καθορίζει τον μέγιστο αριθμό επαναλήψεων για τη σύγκλιση του αλγορίθμου. Εάν ο αλγόριθμος δεν συγκλίνει μετά από τον αριθμό επαναλήψεων που έχει καθοριστεί, η διαδικασία τερματίζεται. Το πλέγμα δοκιμάζει τρεις τιμές: [100, 200, 300].

Συνολικά, το πλέγμα παραμέτρων αυτό δοκιμάζει διαφορετικούς συνδυασμούς κανονικοποιήσεων, τιμών της παραμέτρου C, αλγορίθμων βελτιστοποίησης και μέγιστων επαναλήψεων. Μέσω της διαδικασίας Grid Search, δοκιμάζονται όλοι οι πιθανοί συνδυασμοί αυτών των παραμέτρων, και το μοντέλο εκπαιδεύεται και αξιολογείται με βάση τη μετρική απόδοσης που έχει επιλεγεί. Ο στόχος είναι να βρεθεί ο συνδυασμός παραμέτρων που μεγιστοποιεί την απόδοση του μοντέλου Logistic Regression, διασφαλίζοντας ότι το μοντέλο αποδίδει στο μέγιστο δυνατό επίπεδο.

#### 2.5.4 Παραμέτρων για Neural Network

```
# Define parameter grid for Neural Network
param_grid = {
    'hidden_layer_sizes': [(50,), (100,), (50, 50), (100, 100)],
    'activation': ['tanh', 'relu'],
    'solver': ['sgd', 'adam'],
    'alpha': [0.0001, 0.001, 0.01],
    'learning_rate': ['constant', 'adaptive'],
    'max_iter': [200, 300, 400]
}
```

Αυτό το κομμάτι κώδικα ορίζει το πλέγμα παραμέτρων για τη βελτιστοποίηση ενός μοντέλου Νευρωνικού Δικτύου (Neural Network) μέσω της διαδικασίας Grid Search. Το πλέγμα περιλαμβάνει διαφορετικές τιμές για τις βασικές υπερπαραμέτρους του μοντέλου, και στόχος είναι να βρεθεί ο καλύτερος συνδυασμός που θα μεγιστοποιήσει την απόδοση του νευρωνικού δικτύου.

Οι υπερπαραμέτροι που δοκιμάζονται είναι οι εξής:

1. `hidden_layer_sizes`: Αυτή η παράμετρος καθορίζει τη δομή των κρυφών στρωμάτων στο νευρωνικό δίκτυο. Διαφορετικοί συνδυασμοί μεγεθών στρωμάτων δοκιμάζονται:
  - (50,): Ένα κρυφό στρώμα με 50 νευρώνες.
  - (100,): Ένα κρυφό στρώμα με 100 νευρώνες.
  - (50, 50): Δύο κρυφά στρώματα, το καθένα με 50 νευρώνες.
  - (100, 100): Δύο κρυφά στρώματα, το καθένα με 100 νευρώνες.

Αυτοί οι συνδυασμοί καθορίζουν την αρχιτεκτονική του δικτύου και επηρεάζουν την ικανότητα του μοντέλου να μάθει πιο σύνθετες σχέσεις στα δεδομένα.

2. `activation`: Η παράμετρος αυτή καθορίζει τη συνάρτηση ενεργοποίησης που θα χρησιμοποιηθεί σε κάθε νευρώνα:
  - 'tanh': Η συνάρτηση υπερβολικού εφαπτομένου (tanh), η οποία επιστρέφει τιμές μεταξύ -1 και 1.
  - 'relu': Η συνάρτηση Rectified Linear Unit (ReLU), η οποία επιστρέφει μη γραμμικές τιμές και βοηθά τα νευρωνικά δίκτυα να αντιμετωπίσουν προβλήματα εξασθένισης του σήματος (vanishing gradient).
3. `solver`: Αυτή η παράμετρος καθορίζει τον αλγόριθμο βελτιστοποίησης που θα χρησιμοποιηθεί για την εκπαίδευση του νευρωνικού δικτύου:
  - 'sgd': Ο αλγόριθμος Stochastic Gradient Descent, που κάνει μικρές ενημερώσεις στους βάρων του δικτύου με κάθε δειγματοληψία δεδομένων.
  - 'adam': Ο αλγόριθμος Adam, που είναι μια δημοφιλής επιλογή βελτιστοποίησης καθώς προσαρμόζει τους ρυθμούς εκμάθησης για κάθε παράμετρο και συγκλίνει γρήγορα.
4. `alpha`: Αυτή η παράμετρος είναι ο συντελεστής κανονικοποίησης (regularization term), ο οποίος ελέγχει την ισχύ της κανονικοποίησης για την αποφυγή της υπερεκπαίδευσης. Το πλέγμα περιλαμβάνει τις τιμές [0.0001, 0.001, 0.01], που αντιπροσωπεύουν διαφορετικά επίπεδα κανονικοποίησης.
5. `learning_rate`: Η παράμετρος αυτή καθορίζει τον τρόπο με τον οποίο αλλάζει ο ρυθμός εκμάθησης κατά τη διάρκεια της εκπαίδευσης:
  - 'constant': Ο ρυθμός εκμάθησης παραμένει σταθερός.
  - 'adaptive': Ο ρυθμός εκμάθησης προσαρμόζεται δυναμικά, μειώνοντας την τιμή του όταν η απόδοση του μοντέλου σταθεροποιείται.
6. `max_iter`: Αυτή η παράμετρος καθορίζει τον μέγιστο αριθμό επαναλήψεων για την εκπαίδευση του μοντέλου. Οι τιμές [200, 300, 400] καθορίζουν πόσες επαναλήψεις θα εκτελεστούν πριν τερματιστεί η διαδικασία εκπαίδευσης.

Το πλέγμα αυτό δοκιμάζει διάφορους συνδυασμούς δομών νευρωνικού δικτύου, συναρτήσεων ενεργοποίησης, αλγορίθμων βελτιστοποίησης, τιμών κανονικοποίησης, ρυθμών εκμάθησης και αριθμών επαναλήψεων. Κατά τη διαδικασία Grid Search, όλοι αυτοί οι συνδυασμοί θα δοκιμαστούν για να βρεθεί η βέλτιστη παραμετροποίηση που θα μεγιστοποιήσει την απόδοση του νευρωνικού δικτύου σε ένα σύνολο δεδομένων. Το GridSearchCV θα εκπαιδεύσει το μοντέλο για κάθε συνδυασμό παραμέτρων και θα επιλέξει αυτόν που προσφέρει την καλύτερη απόδοση, με βάση μια μετρική απόδοσης όπως η ακρίβεια ή το F1-score.

- ❖ Εξαίρεση αποτελεί το μοντέλο του naïve bayes διότι δεν έχει παραμέτρους

## 2.6 Διασταυρούμενη Επικύρωση (Cross-Validation)

Η Cross-Validation είναι μια στατιστική μέθοδος που χρησιμοποιείται για την αξιολόγηση και τη βελτίωση της απόδοσης ενός μοντέλου μηχανικής μάθησης. Περιλαμβάνει την κατάτμηση του αρχικού συνόλου δεδομένων σε ένα σύνολο εκπαίδευσης για την εκπαίδευση του μοντέλου και ένα σύνολο επικύρωσης για την αξιολόγησή του. Η διαδικασία αυτή επαναλαμβάνεται πολλές φορές για να εξασφαλιστεί ότι το μοντέλο αποδίδει καλά σε διαφορετικά υποσύνολα των δεδομένων, παρέχοντας μια πιο αξιόπιστη εκτίμηση της απόδοσής του(51).

```
knn = KNeighborsClassifier()  
grid_search = GridSearchCV(knn, param_grid, cv=5, n_jobs=-1,  
scoring='accuracy')  
grid_search.fit(x_train_best, y_train)
```

Το GridSearchCV είναι μια μέθοδος στη βιβλιοθήκη scikit-learn που χρησιμοποιείται για την βελτιστοποίηση υπερπαραμέτρων ενός μοντέλου μηχανικής μάθησης. Σκοπός της είναι να βρει τον καλύτερο συνδυασμό υπερπαραμέτρων που μεγιστοποιεί την απόδοση του μοντέλου, δοκιμάζοντας διαφορετικές τιμές των υπερπαραμέτρων και αξιολογώντας την απόδοση του μοντέλου για κάθε συνδυασμό. Η διαδικασία του GridSearchCV περιλαμβάνει τη δοκιμή όλων των δυνατών συνδυασμών υπερπαραμέτρων από ένα καθορισμένο πλέγμα τιμών (parameter grid), χρησιμοποιώντας διασταυρούμενη επικύρωση (cross-validation) για να αξιολογήσει την απόδοση του κάθε συνδυασμού.

Η διαδικασία της διασταυρούμενης επικύρωσης χωρίζει τα δεδομένα σε K ίσα τμήματα (folds). Για κάθε συνδυασμό παραμέτρων, το μοντέλο εκπαιδεύεται σε K-1 από αυτά τα τμήματα και αξιολογείται στο εναπομείναν τμήμα. Η διαδικασία αυτή επαναλαμβάνεται για όλα τα τμήματα, και η μέση απόδοση του μοντέλου υπολογίζεται για τον εκάστοτε συνδυασμό υπερπαραμέτρων. Στο τέλος, το GridSearchCV επιλέγει τον συνδυασμό υπερπαραμέτρων που είχε την καλύτερη απόδοση σε όλα τα folds και επιστρέφει τον καλύτερο ταξινομητή καθώς και τις βέλτιστες υπερπαραμέτρους.

Ένα παράδειγμα χρήσης του GridSearchCV μπορεί να είναι η βελτιστοποίηση ενός μοντέλου K-Nearest Neighbors (KNN). Σε αυτό το παράδειγμα, το πλέγμα των υπερπαραμέτρων μπορεί να περιλαμβάνει διαφορετικές τιμές για τον αριθμό των γειτόνων (n\_neighbors), τα βάρη (weights) και τη μετρική απόσταση (metric). Ο κώδικας εκτελεί τη διαδικασία GridSearchCV, εκπαιδεύοντας το μοντέλο KNN για κάθε συνδυασμό υπερπαραμέτρων και χρησιμοποιεί την ακρίβεια ως μετρική απόδοσης. Τελικά, επιστρέφεται ο συνδυασμός υπερπαραμέτρων που είχε την υψηλότερη απόδοση, μαζί με την αντίστοιχη ακρίβεια.

Η χρήση του GridSearchCV προσφέρει σημαντικά οφέλη, καθώς αυτοματοποιεί τη διαδικασία επιλογής των υπερπαραμέτρων και εξασφαλίζει ότι η αξιολόγηση γίνεται με αξιόπιστο και στατιστικά επαρκή τρόπο μέσω της διασταυρούμενης επικύρωσης. Παρά τα οφέλη, η διαδικασία μπορεί να γίνει υπολογιστικά απαιτητική όταν το πλέγμα παραμέτρων είναι μεγάλο, λόγω του ότι κάθε πιθανός συνδυασμός υπερπαραμέτρων δοκιμάζεται, κάτι που μπορεί να αυξήσει τον χρόνο εκτέλεσης. Ωστόσο, το GridSearchCV παραμένει ένα από τα πιο ισχυρά εργαλεία για τη βελτιστοποίηση των μοντέλων μηχανικής μάθησης, εξασφαλίζοντας ότι τα μοντέλα αποδίδουν στο βέλτιστο επίπεδο.



Αυτό το κομμάτι του κώδικα εκτελεί τη διαδικασία Grid Search με διασταυρούμενη επικύρωση για τον αλγόριθμο K-Nearest Neighbors (KNN), με σκοπό την εύρεση του βέλτιστου συνδυασμού παραμέτρων. Αρχικά, ο αλγόριθμος KNN αρχικοποιείται χωρίς συγκεκριμένες παραμέτρους, δημιουργώντας ένα αντικείμενο KNeighborsClassifier, το οποίο θα χρησιμοποιηθεί στο Grid Search. Στη συνέχεια, δημιουργείται το αντικείμενο GridSearchCV, το οποίο καθορίζει τις παραμέτρους που θα δοκιμαστούν μέσω του πλέγματος παραμέτρων (param\_grid). Ορίζεται ότι θα χρησιμοποιηθεί 5-πλή διασταυρούμενη επικύρωση (5-fold cross-validation), όπου τα δεδομένα εκπαίδευσης χωρίζονται σε 5 ίσα τμήματα και κάθε φορά ο αλγόριθμος εκπαιδεύεται σε 4 από αυτά και επικυρώνεται στο υπόλοιπο. Αυτό επιτρέπει την αξιόπιστη εκτίμηση της απόδοσης κάθε συνδυασμού παραμέτρων. Η παράμετρος n\_jobs=-1 επιτρέπει την παράλληλη επεξεργασία, χρησιμοποιώντας όλες τις διαθέσιμες επεξεργαστικές μονάδες για να επιταχυνθεί η διαδικασία. Για την αξιολόγηση της απόδοσης, χρησιμοποιείται η ακρίβεια (accuracy) ως μετρική απόδοσης.

Η εντολή grid\_search.fit(x\_train\_best, y\_train)\ εκτελεί την εκπαίδευση του μοντέλου χρησιμοποιώντας το Grid Search. Ο αλγόριθμος KNN εκπαιδεύεται και αξιολογείται σε κάθε συνδυασμό παραμέτρων, και μέσω της διαδικασίας της διασταυρούμενης επικύρωσης, υπολογίζεται η μέση απόδοση για κάθε συνδυασμό. Στο τέλος, το Grid Search επιλέγει τον συνδυασμό παραμέτρων που επιτυγχάνει την καλύτερη ακρίβεια στο σύνολο εκπαίδευσης. Αυτή η διαδικασία βελτιστοποίησης των παραμέτρων διασφαλίζει ότι το μοντέλο KNN είναι ρυθμισμένο με τον βέλτιστο δυνατό τρόπο, με στόχο την καλύτερη απόδοση σε νέα δεδομένα, χωρίς να υπάρχει κίνδυνος υπερεκπαίδευσης στα δεδομένα εκπαίδευσης.

### 2.6.1 Cross-Validation naive bayes

```
# Define the Naive Bayes model
nb = GaussianNB()

# Perform cross-validation using Stratified K-Folds
cv = StratifiedKFold(n_splits=5)
cv_scores = cross_val_score(nb, x_train_best, y_train, cv=cv,
scoring='accuracy')
```

Αυτό το κομμάτι κώδικα αρχικοποιεί ένα μοντέλο Naive Bayes και εφαρμόζει διασταυρούμενη επικύρωση με τη μέθοδο Stratified K-Folds για την εκτίμηση της απόδοσης του μοντέλου.

Η μέθοδος Stratified K-Folds είναι μια τεχνική διασταυρούμενης επικύρωσης που χρησιμοποιείται στη μηχανική μάθηση για την εκτίμηση της απόδοσης ενός μοντέλου, ειδικά όταν τα δεδομένα δεν είναι ισορροπημένα μεταξύ των κατηγοριών. Σε μια τυπική K-Folds cross-validation, τα δεδομένα χωρίζονται σε K ίσα υποσύνολα (folds), και το μοντέλο εκπαιδεύεται και επικυρώνεται σε αυτά. Για κάθε επανάληψη, το μοντέλο εκπαιδεύεται σε K-1 folds και επικυρώνεται στο εναπομείναν fold. Στη συνέχεια, υπολογίζεται ο μέσος όρος των επιδόσεων για να εκτιμηθεί η γενική απόδοση του μοντέλου.

Η διαφορά με την Stratified K-Folds έγκειται στο γεγονός ότι κατά το διαχωρισμό των δεδομένων, λαμβάνεται υπόψη η κατανομή των κατηγοριών. Δηλαδή, διασφαλίζεται ότι κάθε fold έχει την ίδια αναλογία κατηγοριών με το αρχικό σύνολο δεδομένων. Αυτό είναι ιδιαίτερα σημαντικό όταν έχουμε δεδομένα με ανισόρροπες κατηγορίες (π.χ., περισσότερα δείγματα από μία κατηγορία και λιγότερα από άλλη), διότι έτσι διασφαλίζεται ότι κάθε fold αντιπροσωπεύει πιστά την κατανομή των κατηγοριών.

Για παράδειγμα αν έχουμε ένα σύνολο δεδομένων με 70% της μίας κατηγορίας και 30% της άλλης, η χρήση του Stratified K-Folds εξασφαλίζει ότι κάθε fold θα περιέχει 70% δείγματα από την πρώτη κατηγορία και 30% από τη δεύτερη. Έτσι, το μοντέλο θα εκπαιδευτεί και θα επικυρωθεί σε δεδομένα που αντικατοπτρίζουν την πραγματική κατανομή, αποφεύγοντας την υπερεκπροσώπηση της πλειοψηφικής κατηγορίας.

Η Stratified K-Folds αποτρέπει την αδικαιολόγητα υψηλή απόδοση του μοντέλου εξαιτίας της υπερεκπροσώπησης μίας κατηγορίας και προσφέρει πιο αξιόπιστα αποτελέσματα, ιδιαίτερα σε σύνολα δεδομένων με ανισόρροπη κατανομή.

Αρχικά, το μοντέλο Naive Bayes δημιουργείται με τη χρήση της κλάσης GaussianNB(), η οποία εφαρμόζει το θεώρημα του Bayes για την ταξινόμηση δεδομένων, υπό την υπόθεση ότι τα χαρακτηριστικά ακολουθούν μια κανονική κατανομή. Στη συνέχεια, ορίζεται το αντικείμενο cv μέσω της κλάσης 'StratifiedKFold' με τον αριθμό των folds να είναι 5 (n\_splits=5). Η Stratified K-Folds cross-validation διασφαλίζει ότι κάθε fold που θα χρησιμοποιηθεί για την εκπαίδευση και επικύρωση έχει την ίδια αναλογία κατηγοριών όπως το αρχικό σύνολο δεδομένων, κάτι ιδιαίτερα σημαντικό όταν υπάρχουν κατηγορίες με άνιση κατανομή (ανισορροπία).

Μετά, χρησιμοποιείται η συνάρτηση cross\_val\_score, η οποία εφαρμόζει τη διασταυρούμενη επικύρωση με βάση τα folds που έχουν δημιουργηθεί. Το cross\_val\_score εκπαιδεύει και αξιολογεί το μοντέλο Naive Bayes (το οποίο αντιπροσωπεύεται από το αντικείμενο nb) για κάθε fold. Σε κάθε επανάληψη, το μοντέλο εκπαιδεύεται σε 4 από τα 5 folds και επικυρώνεται στο εναπομείναν fold. Η διαδικασία επαναλαμβάνεται για κάθε fold και τα αποτελέσματα καταγράφονται.

Η μετρική που χρησιμοποιείται για την αξιολόγηση του μοντέλου είναι η ακρίβεια (scoring='accuracy'), η οποία εκφράζει το ποσοστό των σωστών προβλέψεων σε σχέση με το σύνολο των προβλέψεων. Η συνάρτηση cross\_val\_score επιστρέφει τις ακρίβειες για κάθε fold και τα αποτελέσματα αποθηκεύονται στη μεταβλητή cv\_scores, η οποία περιέχει τις ακρίβειες από κάθε επανάληψη της διασταυρούμενης επικύρωσης.

Με αυτή τη διαδικασία, επιτυγχάνεται μια πιο αξιόπιστη εκτίμηση της απόδοσης του μοντέλου, καθώς λαμβάνεται υπόψη η μεταβλητότητα στα δεδομένα και αποφεύγεται η υπερεκπαίδευση ή υποεκπαίδευση σε ένα μόνο σύνολο δεδομένων. Η χρήση του Stratified K-Folds διασφαλίζει ότι η αξιολόγηση γίνεται με αντιπροσωπευτικά σύνολα δεδομένων για την ταξινόμηση, διατηρώντας τη σωστή αναλογία κατηγοριών σε κάθε fold.

## 2.7 Αξιολόγηση μοντέλων

```
# Get the best model
best_model = grid_search.best_estimator_
best_params = grid_search.best_params_
best_accuracy = grid_search.best_score_
```

```
print(f"Best Features: {best_features}, Best Params: {best_params},  
Accuracy: {best_accuracy:.4f}")  
  
# Validate the best model on the validation set  
y_pred = best_model.predict(x_valid_best)  
  
# Print classification report  
report = classification_report(y_valid, y_pred)  
print("Classification Report:\n", report)  
  
# Calculate ROC curve and AUC for the validation set  
y_prob = best_model.predict_proba(x_valid_best)[: , 1] # Get probability  
estimates for the positive class  
fpr, tpr, _ = roc_curve(y_valid, y_prob)  
roc_auc = auc(fpr, tpr)  
  
# Plot the ROC curve  
plt.figure()  
plt.plot(fpr, tpr, color='darkorange', lw=2, label=f'ROC curve (AUC =  
{roc_auc:.4f})')  
plt.plot([0, 1], [0, 1], color='navy', lw=2, linestyle='--')  
plt.xlim([0.0, 1.0])  
plt.ylim([0.0, 1.05])  
plt.xlabel('False Positive Rate')  
plt.ylabel('True Positive Rate')  
plt.title('Receiver Operating Characteristic')  
plt.legend(loc="lower right")  
plt.show()  
  
# Print confusion matrix  
conf_matrix = confusion_matrix(y_valid, y_pred)  
disp = ConfusionMatrixDisplay(confusion_matrix=conf_matrix)  
disp.plot()  
plt.title("Confusion Matrix")  
plt.show()
```

```
# Print ROC AUC
print(f"AUC (ROC): {roc_auc:.4f}")
```

Αυτό το κομμάτι κώδικα αφορά την αξιολόγηση του καλύτερου μοντέλου που προέκυψε από τη διαδικασία του Grid Search και περιλαμβάνει τόσο την ποσοτική όσο και την ποιοτική ανάλυση της απόδοσής του. Η διαδικασία αξιολόγησης περιλαμβάνει την εξαγωγή του βέλτιστου μοντέλου και των παραμέτρων του, την πρόβλεψη των κατηγοριών για το σύνολο επικύρωσης, τον υπολογισμό των κύριων μετρικών απόδοσης, καθώς και την οπτικοποίηση των αποτελεσμάτων με τη χρήση της καμπύλης ROC και του confusion matrix.

Αρχικά, το καλύτερο μοντέλο από το Grid Search αποθηκεύεται στη μεταβλητή `best_model` μέσω της μεθόδου `best_estimator_`. Αυτή η μέθοδος επιστρέφει το μοντέλο που πέτυχε την υψηλότερη απόδοση από όλους τους συνδυασμούς παραμέτρων που δοκιμάστηκαν κατά τη διαδικασία του Grid Search. Ταυτόχρονα, η μέθοδος `best_params_` εξάγει και αποθηκεύει τις βέλτιστες παραμέτρους στη μεταβλητή `best_params`, δηλαδή τις ρυθμίσεις (όπως ο αριθμός γειτόνων και ο τύπος βαρών) που οδήγησαν στο καλύτερο αποτέλεσμα. Η ακρίβεια του μοντέλου κατά τη διαδικασία του Grid Search αποθηκεύεται στη μεταβλητή `best_score_` και αποτυπώνει την καλύτερη επίδοση του μοντέλου κατά τη διασταυρούμενη επικύρωση (cross-validation). Αυτές οι πληροφορίες εκτυπώνονται, ώστε να παρέχουν μια συνοπτική αναφορά του καλύτερου μοντέλου, των βέλτιστων παραμέτρων του και της απόδοσής του.


Αφού εντοπιστεί το καλύτερο μοντέλο, εφαρμόζεται στο σύνολο επικύρωσης (`x_valid_best`) με τη χρήση της μεθόδου `predict`, η οποία προβλέπει τις κατηγορίες για τα δείγματα του συνόλου επικύρωσης. Τα αποτελέσματα αποθηκεύονται στη μεταβλητή `y_pred`, που περιέχει τις προβλέψεις για κάθε δείγμα. Στη συνέχεια, με τη χρήση της συνάρτησης `classification_report` από τη βιβλιοθήκη `sklearn`, δημιουργείται ένα αναλυτικό `classification report`, το οποίο περιλαμβάνει βασικές μετρικές όπως:

- Precision : Το ποσοστό των σωστών θετικών προβλέψεων σε σχέση με όλες τις προβλέψεις για μια κατηγορία.
- Recall (Ανάκληση): Το ποσοστό των σωστών θετικών προβλέψεων σε σχέση με τα πραγματικά θετικά παραδείγματα.
- F1-Score: Η αρμονική μέση του Precision και του Recall, η οποία αποτελεί μέτρο της ισορροπίας μεταξύ των δύο.
- Support: Ο αριθμός των δειγμάτων σε κάθε κατηγορία.

Αυτό το report δίνει μια λεπτομερή εικόνα της απόδοσης του μοντέλου για κάθε κατηγορία του συνόλου επικύρωσης και εκτυπώνεται ώστε να αναλυθεί η συνολική ακρίβεια του μοντέλου.

Στη συνέχεια, η απόδοση του μοντέλου αναλύεται μέσω της καμπύλης ROC (Receiver Operating Characteristic), η οποία παρέχει μια οπτική αναπαράσταση της ικανότητας του μοντέλου να διαχωρίσει τις κατηγορίες. Για να δημιουργηθεί η καμπύλη ROC, χρησιμοποιείται η μέθοδος `predict_proba` του καλύτερου μοντέλου, η οποία επιστρέφει τις εκτιμήσεις πιθανότητας για κάθε δείγμα. Εδώ, λαμβάνονται οι πιθανότητες για την θετική κατηγορία (positive class) και χρησιμοποιούνται για να υπολογιστούν οι τιμές του False Positive Rate (FPR) και του True Positive Rate (TPR) μέσω της συνάρτησης `roc_curve`. Στη συνέχεια, υπολογίζεται η AUC (Area Under Curve), η οποία εκφράζει την περιοχή κάτω από την καμπύλη ROC και παρέχει μια συνολική μετρική της απόδοσης του μοντέλου στη διάκριση μεταξύ των κατηγοριών. Η καμπύλη ROC σχεδιάζεται με τη χρήση της `matplotlib`,

όπου το FPR τοποθετείται στον οριζόντιο άξονα και το TPR στον κατακόρυφο, με μια διακεκομμένη γραμμή που αντιπροσωπεύει τη γραμμή τυχαιάς πρόβλεψης.



Εικόνα 2.1: Διαγραμμα roc(52)

- **Τέλεια απόδοση (AUC = 1.0):**

Μια τιμή **AUC ίση με 1** υποδηλώνει ότι το μοντέλο είναι τέλει και μπορεί να διακρίνει πάντα σωστά μεταξύ των θετικών και αρνητικών περιπτώσεων. Στην καμπύλη ROC, αυτό αντιστοιχεί σε μια γραμμή που ακολουθεί τον άξονα των y και φτάνει στην επάνω αριστερή γωνία (True Positive Rate = 1, False Positive Rate = 0), πριν ακολουθήσει τον άξονα των x.

- **Τυχαία απόδοση (AUC = 0.5):**

Μια τιμή **AUC ίση με 0.5** υποδηλώνει ότι το μοντέλο δεν έχει ικανότητα διάκρισης μεταξύ θετικών και αρνητικών περιπτώσεων. Αυτό συμβαίνει όταν το μοντέλο λειτουργεί σαν να κάνει τυχαίες προβλέψεις. Στην καμπύλη ROC, αυτή η τιμή αντιπροσωπεύεται από μια διαγώνια γραμμή από το (0,0) στο (1,1), καθώς το ποσοστό των False Positives είναι ίσο με το ποσοστό των True Positives σε όλα τα κατώφλια.

- **Κακή απόδοση (AUC < 0.5):**

Αν το AUC είναι μικρότερο από **0.5**, τότε το μοντέλο αποδίδει χειρότερα από την τυχαία πρόβλεψη, κάτι που σημαίνει ότι οι προβλέψεις του είναι αντιστραμμένες. Αυτό είναι συνήθως ένδειξη ότι κάτι δεν πάει καλά με το μοντέλο ή τα δεδομένα.

Επιπλέον, υπολογίζεται και εμφανίζεται το Confusion Matrix, το οποίο παρέχει μια σαφή απεικόνιση των αληθών και ψευδών προβλέψεων του μοντέλου. Το confusion matrix δείχνει τον αριθμό των αληθών θετικών (True Positives), αληθών αρνητικών (True Negatives),

ψευδών θετικών (False Positives) και ψευδών αρνητικών (False Negatives), παρέχοντας μια πιο λεπτομερή εικόνα των επιδόσεων του μοντέλου σε κάθε κατηγορία. Το Confusion Matrix σχεδιάζεται μέσω της ConfusionMatrixDisplay, η οποία δημιουργεί έναν εύκολα αναγνώσιμο πίνακα, τονίζοντας την ακρίβεια των προβλέψεων για κάθε κατηγορία.

		Ground truth		
		+	-	
Predicted	+	True positive (TP)	False positive (FP)	Precision = $TP / (TP + FP)$
	-	False negative (FN)	True negative (TN)	
		Recall = $TP / (TP + FN)$		Accuracy = $(TP + TN) / (TP + FP + TN + FN)$

Εικόνα 2.2: Μήτρα σύγχυσης (53)

### 3 Αποτελέσματα

#### 3.1 Εισαγωγή στα αποτελέσματα

Σε αυτή την ενότητα, διερευνούμε συστηματικά την απόδοση διαφόρων μοντέλων μηχανικής μάθησης-K-Nearest Neighbors (KNN), Support Vector Machines (SVM), Logistic Regression, Naive Bayes και Neural Networks-που εφαρμόζονται στο σύνολο δεδομένων που παράγεται από την ενδοεγχειρητική νευροπαρακολούθηση (IONM). Ο στόχος είναι να προσδιοριστεί ποιο μοντέλο ή μοντέλα προσφέρουν την καλύτερη ισορροπία μεταξύ της ακρίβειας, της ακρίβειας, της ανάκλησης και του F1-score, διασφαλίζοντας έτσι ότι το επιλεγμένο μοντέλο παρέχει αξιόπιστες προβλέψεις κατά τη διάρκεια της χειρουργικής επέμβασης.

Δεδομένης της κρίσιμης φύσης της εφαρμογής, επιλέχθηκαν αυτές οι μετρικές για να αξιολογηθεί όχι μόνο η συνολική ορθότητα των προβλέψεων (ακρίβεια), αλλά και η ικανότητα του μοντέλου να εντοπίζει σωστά τις αληθινά θετικές περιπτώσεις (recall), να αποφεύγει τα ψευδώς θετικά αποτελέσματα (precision) και να παρέχει ένα ισορροπημένο μέτρο που λαμβάνει υπόψη τόσο την ακρίβεια όσο και την ανάκληση (F1-score).

#### 3.2 Παρουσίαση των αποτελεσμάτων για κάθε μοντέλο μηχανικής μάθησης

Τα αποτελέσματα κάθε μοντέλου παρουσιάζονται ως προς την ακρίβεια, precision, recall, το F1-score. Αυτή η λεπτομερής ανάλυση μας επιτρέπει να εξετάσουμε τα δυνατά και αδύνατα σημεία κάθε μοντέλου στο πλαίσιο της ανίχνευσης κρίσιμων νευρικών συμβάντων κατά τη διάρκεια της χειρουργικής επέμβασης.

ΠΙΝΑΚΑΣ 3.1 ΑΠΟΤΕΛΕΣΜΑΤΑ ΜΟΝΤΕΛΩΝ

Model	Accuracy	Recall	Precision	F1-Score	AUC
<b>KNN</b>	0.9182	0.67	0.61	0.64	0.6372
<b>Naive Bayes</b>	0.7284	0.72	0.37	0.49	0.7319
<b>SVM</b>	0.9114	0.67	0.88	0.76	0.8317
<b>Logistic Regression</b>	0.7432	0.67	0.44	0.53	0.6955
<b>Neural Network</b>	0.9545	0.67	0.93	0.78	0.8431


##### 3.2.1 Αποτελέσματα KNN

Το μοντέλο K-Nearest Neighbors (KNN) που εφαρμόστηκε για την ταξινόμηση των δεδομένων έδωσε ως αποτέλεσμα ακρίβεια 91.82%. Οι βέλτιστες υπερπαραμέτροι που βρέθηκαν μέσω της διαδικασίας Grid Search είναι η χρήση της μετρικής Manhattan για τον υπολογισμό των αποστάσεων, ο αριθμός γειτόνων που ορίστηκε στους 3 και τα βάρη που βασίζονται στην απόσταση, όπου οι κοντινότεροι γείτονες έχουν μεγαλύτερη επιρροή στην πρόβλεψη.

Όσον αφορά τα αποτελέσματα της ταξινόμησης, το classification report δείχνει ότι το μοντέλο αποδίδει καλύτερα στην ταξινόμηση της κατηγορίας 0 (φυσιολογικό), με precision 0.90, recall 0.87 και F1-score 0.89, πράγμα που σημαίνει ότι το 90% των προβλέψεων για την κατηγορία

0 είναι σωστές και το 87% των πραγματικών παραδειγμάτων της κατηγορίας 0 αναγνωρίζονται σωστά. Αντίθετα, για την κατηγορία 1 (βλαβη), το precision είναι 0.61, το recall 0.67 και το F1-score 0.64, υποδηλώνοντας ότι η απόδοση του μοντέλου είναι χαμηλότερη για αυτήν την κατηγορία. Ειδικότερα, το 61% των προβλέψεων για την κατηγορία 1 είναι σωστές, ενώ το 67% των πραγματικών παραδειγμάτων της κατηγορίας 1 αναγνωρίζονται σωστά.

Η συνολική ακρίβεια του μοντέλου είναι 83%, που σημαίνει ότι το μοντέλο προβλέπει σωστά το 83% των περιπτώσεων στο σύνολο επικύρωσης. Συμπερασματικά, το μοντέλο αποδίδει καλά στη διάκριση των παραδειγμάτων της κατηγορίας 0, αλλά εμφανίζει χαμηλότερη απόδοση στην κατηγορία 1, γεγονός που μπορεί να οφείλεται στην ανισορροπία των δεδομένων ή στην ανάγκη περαιτέρω βελτιστοποίησης του μοντέλου για καλύτερη αναγνώριση των θετικών παραδειγμάτων.




Εικόνα 3.1: ROC KNN

Το AUC (Area Under the Curve) είναι 0.6372, που σημαίνει ότι το μοντέλο μπορεί να διακρίνει μεταξύ των κατηγοριών με ακρίβεια 63.72%. Αν και καλύτερη από την τυχαία πρόβλεψη, η τιμή αυτή υποδηλώνει ότι το μοντέλο έχει περιθώρια βελτίωσης.

Η υψηλή τιμή των False Positives και False Negatives υποδεικνύει ότι το μοντέλο κάνει λάθος προβλέψεις και στις δύο κατηγορίες, κυρίως όμως δυσκολεύεται στην αναγνώριση της κατηγορίας 1 (θετικά δείγματα). Αυτό φαίνεται και από την τιμή του AUC, καθώς και από το γεγονός ότι το μοντέλο προβλέπει περισσότερα παραδείγματα της κατηγορίας 0 σωστά από την κατηγορία 1.





Εικόνα 3.2: CONFUSION MATRIX KNN

Από τους παραπάνω πίνακες μπορούμε να εξάγουμε αρκετά συμπεράσματα ως προς την αποτελεσματικότητα των χαρακτηριστικών, των παραμέτρων και του κάθε μοντέλου. Αρχικά ως αναφερθεί το καλύτερο δυνατό αποτέλεσμα για κάθε μοντέλο και στη συνέχεια να συγκρίνουμε τα μοντέλα αυτά μεταξύ τους.


### 3.2.2 Αποτελέσματα Naive Bayes

Το μοντέλο παρουσιάζει μια μέτρια απόδοση με βάση τα αποτελέσματα της διασταυρούμενης επικύρωσης και το classification report. Η διασταυρούμενη επικύρωση δείχνει ότι η απόδοση του μοντέλου στα 5 folds κυμαίνεται με σκορ: [0.752, 0.769, 0.733, 0.733, 0.655]. Η μέση ακρίβεια υπολογίστηκε στο 72.84%, με μια τυπική απόκλιση 0.0391, που δείχνει ότι το μοντέλο παρουσιάζει σχετική σταθερότητα στις διαφορετικές επικυρώσεις, με μικρές διακυμάνσεις στην απόδοσή του.

Στο σύνολο επικύρωσης, το μοντέλο παρουσιάζει συνολική ακρίβεια 71%, που σημαίνει ότι προβλέπει σωστά το 71% των περιπτώσεων από τα δείγματα του συνόλου. Ωστόσο, υπάρχει σημαντική διαφορά στην απόδοση μεταξύ των δύο κατηγοριών.


Για την κατηγορία 0, το μοντέλο επιτυγχάνει precision 0.91, που σημαίνει ότι το 91% των προβλέψεων για την κατηγορία 0 είναι σωστές. Το recall είναι 0.71, που σημαίνει ότι το μοντέλο αναγνωρίζει σωστά το 71% των παραδειγμάτων της κατηγορίας 0. Το F1-score για την κατηγορία 0 είναι 0.80, που δείχνει έναν καλό συνδυασμό ακρίβειας και ανάκλησης για αυτή την κατηγορία.

Αντίθετα, στην κατηγορία 1, το μοντέλο παρουσιάζει χαμηλότερη απόδοση. Το precision είναι μόλις 0.37, υποδεικνύοντας ότι μόνο το 37% των προβλέψεων για την κατηγορία 1 είναι σωστές. Ωστόσο, το recall είναι 0.72, πράγμα που σημαίνει ότι το μοντέλο καταφέρνει να ανιχνεύσει το 72% των πραγματικών παραδειγμάτων της κατηγορίας 1. Το F1-score είναι 0.49, υποδεικνύοντας μια μέτρια ισορροπία ανάμεσα στην ακρίβεια και την ανάκληση για αυτή την κατηγορία.



Εικόνα 3.3: ROC ΝΑΪΒΕ BAYES

Η Area Under the Curve (AUC) είναι 0.7319, υποδεικνύοντας μια σχετικά καλή ικανότητα του μοντέλου να διακρίνει μεταξύ των δύο κατηγοριών. Η γραμμή της ROC καμπύλης δείχνει ότι το μοντέλο έχει καλύτερη απόδοση από την τυχαία πρόβλεψη (που θα είχε AUC = 0.5), αλλά υπάρχει περιθώριο βελτίωσης.



Εικόνα 3.4: CONFUSION MATRIX ΝΑΪΒΕ BAYES

Το confusion matrix δείχνει ότι το μοντέλο προβλέπει αρκετά σωστά τα παραδείγματα της κατηγορίας 0, αλλά αντιμετωπίζει δυσκολίες στην αναγνώριση της κατηγορίας 1. Συγκεκριμένα, υπάρχουν 22 False Positives και 5 False Negatives, κάτι που υποδεικνύει ότι το μοντέλο έχει κάποιες δυσκολίες στον εντοπισμό της κατηγορίας 1, αν και τα True Positives είναι περισσότερα από τα False Negatives, κάτι που είναι θετικό.

Συνολικά, η AUC = 0.7319 δείχνει ότι το μοντέλο έχει σχετικά καλή ικανότητα διάκρισης μεταξύ των κατηγοριών, αλλά το confusion matrix αποκαλύπτει ότι υπάρχουν αρκετά λάθη (False Positives και False Negatives), κάτι που υποδεικνύει ότι το μοντέλο χρειάζεται περαιτέρω βελτιστοποίηση για καλύτερη απόδοση, ειδικά στην κατηγορία 1.


### 3.2.3 Αποτελέσματα SVM

Το μοντέλο παρουσιάζει εξαιρετική απόδοση με βάση τις βέλτιστες παραμέτρους που βρέθηκαν μέσω της διαδικασίας βελτιστοποίησης. Οι βέλτιστες παράμετροι είναι: C = 10, gamma = 'scale' και kernel = 'rbf', ενώ η συνολική ακρίβεια του μοντέλου είναι 91.14%.

Για την κατηγορία 0, το μοντέλο έχει precision 0.91, που σημαίνει ότι το 91% των προβλέψεων για την κατηγορία 0 είναι σωστές. Το recall είναι 0.97, υποδεικνύοντας ότι το μοντέλο αναγνωρίζει σχεδόν όλα τα παραδείγματα της κατηγορίας 0, με F1-score 0.94, που δείχνει την ισορροπία μεταξύ ακρίβειας και ανάκλησης.


Για την κατηγορία 1, το μοντέλο παρουσιάζει precision 0.88, που σημαίνει ότι το 88% των προβλέψεων για την κατηγορία 1 είναι σωστές. Ωστόσο, το recall είναι χαμηλότερο, στο 0.67, που δείχνει ότι το μοντέλο δεν αναγνωρίζει όλα τα παραδείγματα της κατηγορίας 1, με F1-score 0.76, που υποδεικνύει μέτρια απόδοση σε αυτή την κατηγορία.

Η συνολική ακρίβεια του μοντέλου είναι 90%, κάτι που δείχνει ότι το μοντέλο ταξινομεί σωστά το 90% των περιπτώσεων στο σύνολο δεδομένων επικύρωσης.



Εικόνα 3.5: ROC SVM

Η AUC τιμή 0.8317 δείχνει ότι το μοντέλο έχει εξαιρετική ικανότητα διάκρισης μεταξύ των κατηγοριών, καθώς όσο πιο κοντά στο 1.0 είναι η AUC, τόσο καλύτερη είναι η απόδοση του μοντέλου στη διάκριση μεταξύ των κατηγοριών.



Εικόνα 3.6: CONFUSION MATRIX SVM


Το μοντέλο επιδεικνύει πολύ καλή απόδοση στην κατηγορία 0, με ελάχιστα False Positives, αλλά υπάρχει ακόμα χώρος για βελτίωση στην κατηγορία 1, καθώς σημειώνονται 7 False Negatives. Παρόλα αυτά, η συνολική ικανότητα διάκρισης μεταξύ των κατηγοριών, όπως υποδηλώνεται από την  $AUC = 0.8317$ , είναι εξαιρετική, δείχνοντας ότι το μοντέλο είναι αξιόπιστο και επιτυγχάνει υψηλή απόδοση στη διάκριση των κατηγοριών.

### 3.2.4 Αποτελέσματα Logistic Regression

Το μοντέλο Logistic Regression παρουσίασε μέτρια απόδοση με ακρίβεια 74.32%, χρησιμοποιώντας τις βέλτιστες υπερπαραμέτρους:  $C = 0.1$ ,  $max\_iter = 100$ ,  $penalty = 'l1'$ , και  $solver = 'liblinear'$ . Αυτό σημαίνει ότι η κανονικοποίηση L1 με τον liblinear solver παρέχει σχετικά ικανοποιητικά αποτελέσματα. Στην κατηγορία 0, το μοντέλο πέτυχε precision 0.88, που σημαίνει ότι το 88% των προβλέψεων για αυτή την κατηγορία ήταν σωστές, ενώ το recall ήταν 0.75, δηλαδή το μοντέλο αναγνώρισε σωστά το 75% των πραγματικών παραδειγμάτων της κατηγορίας. Το F1-score για την κατηγορία 0 ήταν 0.81, υποδεικνύοντας μια ισορροπημένη απόδοση μεταξύ ακρίβειας και ανάκλησης.


Αντίθετα, στην κατηγορία 1 η απόδοση ήταν χαμηλότερη, με precision 0.44, που σημαίνει ότι μόνο το 44% των προβλέψεων για την κατηγορία αυτή ήταν σωστές. Το recall ήταν 0.67, δηλαδή το μοντέλο κατάφερε να αναγνωρίσει το 67% των παραδειγμάτων της κατηγορίας 1. Το F1-score ήταν 0.53, υποδεικνύοντας μέτρια απόδοση.

Αυτά τα αποτελέσματα δείχνουν ότι η απόδοση του μοντέλου είναι ικανοποιητική, αλλά η απόδοσή του στην κατηγορία 1 είναι περιορισμένη, γεγονός που επηρεάζει τον μέσο όρο



Εικόνα 3.7: ROC LOGISTIC REGRESSION

Η Area Under the Curve (AUC) είναι 0.6955, που υποδεικνύει ότι το μοντέλο έχει σχετική ικανότητα διάκρισης μεταξύ των κατηγοριών, αν και δεν είναι ιδιαίτερα υψηλή. Μια τιμή AUC κοντά στο 0.7 υποδηλώνει ότι το μοντέλο είναι καλύτερο από την τυχαία πρόβλεψη, αλλά υπάρχουν περιθώρια βελτίωσης.



Εικόνα 3.8: CONFUSION MATRIX LOGISTIC REGRESSION

Από τα παραπάνω δεδομένα, είναι προφανές ότι το μοντέλο έχει καλή απόδοση στην πρόβλεψη της κατηγορίας 0, αλλά δυσκολεύεται περισσότερο στην αναγνώριση της κατηγορίας 1. Ο αριθμός των False Positives (18) είναι σχετικά υψηλός, ενώ υπάρχει και σημαντικός αριθμός False Negatives (7), κάτι που δείχνει ότι το μοντέλο χάνει κάποια

δείγματα της κατηγορίας 1. Συνολικά, η AUC 0.6955 δείχνει ότι το μοντέλο λειτουργεί μετρίως και υπάρχει ανάγκη για περαιτέρω βελτίωση, ειδικά στην κατηγορία 1.

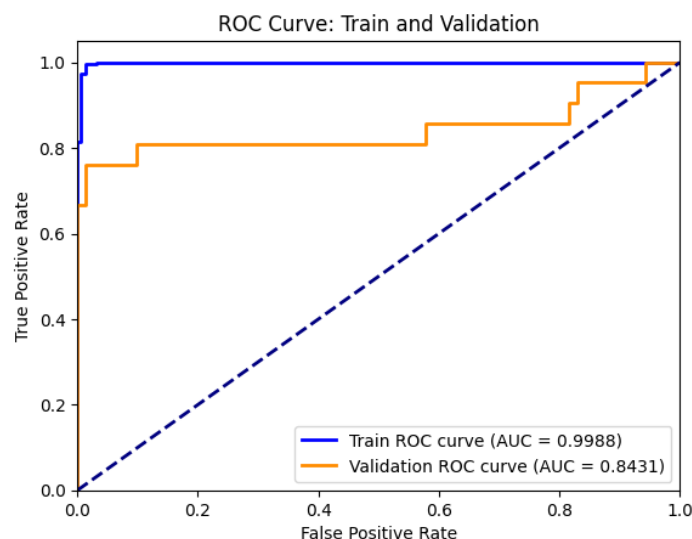
### 3.2.5 Αποτελέσματα Neural Network

Το μοντέλο παρουσίασε πολύ καλή απόδοση με ακρίβεια 95.45%, χρησιμοποιώντας τις βέλτιστες υπερπαραμέτρους: ενεργοποίηση 'relu', alpha 0.0001, δύο κρυφά στρώματα με 100 νευρώνες το καθένα, σταθερό ρυθμό εκμάθησης και 400 μέγιστες επαναλήψεις, ενώ για την εκπαίδευση χρησιμοποιήθηκε ο solver 'adam'.

Η απόδοση του μοντέλου στην κατηγορία 0 ήταν εξαιρετική, με precision 0.91 και recall 0.99, δείχνοντας ότι το μοντέλο εντόπισε σχεδόν όλα τα παραδείγματα της κατηγορίας αυτής, με έναν πολύ υψηλό συνδυασμό ακρίβειας και ανάκλησης, αποδίδοντας F1-score 0.95. Αυτό υποδηλώνει ότι το μοντέλο είναι πολύ αποτελεσματικό στη διάκριση των δειγμάτων της κατηγορίας 0.


Για την κατηγορία 1, το precision ήταν επίσης υψηλό, στο 0.93, που δείχνει ότι η πλειοψηφία των προβλέψεων για την κατηγορία 1 ήταν σωστές. Ωστόσο, το recall ήταν χαμηλότερο, στο 0.67, υποδεικνύοντας ότι το μοντέλο δεν κατάφερε να ανιχνεύσει όλα τα παραδείγματα της κατηγορίας 1. Αυτό επηρεάζει το F1-score, το οποίο ήταν 0.78 για την κατηγορία 1, δείχνοντας ότι παρόλο που οι σωστές προβλέψεις ήταν αρκετές, το μοντέλο δυσκολεύτηκε να αναγνωρίσει πλήρως όλα τα θετικά παραδείγματα.

Συνολικά, η ακρίβεια του μοντέλου ήταν 91%, και τα σταθμισμένα μέσα δείχνουν έναν εξαιρετικά ισορροπημένο συνδυασμό ακρίβειας, ανάκλησης και F1-score, με τιμές κοντά στο 91% για όλες τις μετρικές. Ωστόσο, ο μέσος όρος των μετρικών δείχνει μια μικρή πτώση, λόγω της χαμηλότερης απόδοσης στην κατηγορία 1, με recall 0.83. Παρόλο που το μοντέλο αποδίδει πολύ καλά στη γενική ταξινόμηση, υπάρχει περιθώριο βελτίωσης ειδικά στη διάκριση των παραδειγμάτων της κατηγορίας 1, τα οποία δεν αναγνωρίζονται πλήρως.



Εικόνα 3.9: ROC NEURAL NETWORK

Η καμπύλη εκπαίδευσης έχει AUC (Area Under the Curve) ίσο με 0.9988, που υποδεικνύει σχεδόν τέλεια απόδοση του μοντέλου στο σύνολο εκπαίδευσης. Αυτό σημαίνει ότι το μοντέλο καταφέρνει να ξεχωρίσει τα θετικά από τα αρνητικά δείγματα με εξαιρετική ακρίβεια κατά την εκπαίδευση. Η καμπύλη ROC για το σύνολο επικύρωσης έχει AUC ίσο με 0.8431, το οποίο, αν και είναι χαμηλότερο από το AUC της εκπαίδευσης, εξακολουθεί να είναι υψηλό και να δείχνει καλή απόδοση του μοντέλου στο σύνολο επικύρωσης. Η διαφορά μεταξύ των δύο AUC (εκπαίδευσης και επικύρωσης) μπορεί να υποδηλώνει μια μικρή τάση του μοντέλου να "ταιριάζει υπερβολικά" στα δεδομένα εκπαίδευσης (overfitting), αλλά η απόδοση στην επικύρωση παραμένει ικανοποιητική.



Εικόνα 3.10: CONFUSION MATRIX NEURAL NETWORK

Συμπερασματικά, το μοντέλο έχει πολύ καλή απόδοση τόσο στην εκπαίδευση όσο και στην επικύρωση, με την καμπύλη ROC να επιβεβαιώνει τη διάκριση μεταξύ θετικών και αρνητικών δειγμάτων. Το confusion matrix αποκαλύπτει ότι το μοντέλο έχει εξαιρετική ακρίβεια στην κατηγορία 0, ενώ παρουσιάζει κάποιες αδυναμίες στην κατηγορία 1, όπου το ποσοστό των ψευδώς αρνητικών προβλέψεων είναι μεγαλύτερο.

## 4 Συμπεράσματα

Με βάση τα παραπάνω το μοντέλο με τα καλύτερα αποτελέσματα αποτελεί το neural network. Τα νευρωνικά δίκτυα, ιδίως τα μοντέλα βαθιάς μάθησης, είναι ιδιαίτερα ευέλικτα και ικανά να αποτυπώνουν πολύπλοκες, μη γραμμικές σχέσεις στα δεδομένα. Υπερέχουν σε σενάρια όπου τα δεδομένα είναι μεγάλα και αδόμητα, όπως εικόνες ή σήματα. Στην ΙΟΝΜ, όπου μπορεί να υπάρχουν πολύπλοκες αλληλεπιδράσεις μεταξύ των νευρωνικών σημάτων, τα νευρωνικά δίκτυα μπορούσαν να παρέχουν ανώτερες επιδόσεις καταγράφοντας αυτές τις μη γραμμικές σχέσεις.

### 4.1 Σύγκριση μοντέλων

Η αξιολόγηση των αποτελεσμάτων από τα διάφορα μοντέλα, όπως παρουσιάζονται στο έγγραφο, αποκαλύπτει τα εξής σχετικά με τις μετρικές ακρίβειας, precision, recall και F1-score:

Το μοντέλο K-Nearest Neighbors (KNN) έδωσε μια συνολική ακρίβεια 91.82%. Το precision για την κατηγορία 0 ήταν 0.90, που σημαίνει ότι το 90% των προβλέψεων για αυτήν την κατηγορία ήταν σωστές, ενώ το recall ήταν 0.87, υποδηλώνοντας ότι το μοντέλο αναγνώρισε σωστά το 87% των παραδειγμάτων της κατηγορίας 0. Το F1-score ήταν 0.89, δείχνοντας μια καλή ισορροπία μεταξύ ακρίβειας και ανάκλησης. Στην κατηγορία 1, το precision ήταν χαμηλότερο (0.61), και το recall 0.67, κάτι που υποδηλώνει ότι το μοντέλο δυσκολεύεται να αναγνωρίσει πλήρως τα θετικά παραδείγματα της κατηγορίας αυτής, με F1-score 0.64. Συνολικά, η απόδοση του μοντέλου δείχνει μια ανισορροπία στις δύο κατηγορίες, με σαφή πλεονέκτημα στην κατηγορία 0, κάτι που ενδεχομένως οφείλεται στην ανισορροπία των δεδομένων.

Το Naïve Bayes μοντέλο παρουσίασε μέση ακρίβεια 72.84%, με σημαντικές διαφορές μεταξύ των δύο κατηγοριών. Το precision για την κατηγορία 0 ήταν 0.91, και το recall 0.71, με F1-score 0.80, υποδεικνύοντας καλή απόδοση στην κατηγορία αυτή. Στην κατηγορία 1, ωστόσο, το precision ήταν μόνο 0.37, αν και το recall ήταν υψηλότερο (0.72), κάτι που υποδηλώνει ότι το μοντέλο αναγνωρίζει σωστά τα περισσότερα παραδείγματα της κατηγορίας, αλλά κάνει αρκετά λάθη στην κατηγορία 1. Το F1-score ήταν 0.49, δείχνοντας μια μέτρια ισορροπία.

Το SVM μοντέλο είχε εξαιρετική απόδοση με ακρίβεια 91.14%. Για την κατηγορία 0, το precision ήταν 0.91 και το recall 0.97, με F1-score 0.94, υποδεικνύοντας πολύ καλή ικανότητα του μοντέλου να αναγνωρίζει τα παραδείγματα της κατηγορίας 0. Στην κατηγορία 1, το μοντέλο είχε precision 0.88, αλλά το recall ήταν χαμηλότερο (0.67), δείχνοντας ότι το μοντέλο δεν αναγνωρίζει πλήρως όλα τα παραδείγματα της κατηγορίας 1, με F1-score 0.76.

Το Logistic Regression μοντέλο εμφάνισε μέση απόδοση με ακρίβεια 74.32%. Για την κατηγορία 0, το precision ήταν 0.88, με recall 0.75 και F1-score 0.81, δείχνοντας καλή ισορροπία μεταξύ ακρίβειας και ανάκλησης. Για την κατηγορία 1, το precision ήταν χαμηλότερο (0.44), και το recall 0.67, ενώ το F1-score ήταν 0.53, δείχνοντας ότι η απόδοση του μοντέλου στην κατηγορία αυτή είναι πιο περιορισμένη.

Τέλος, το Neural Network μοντέλο έδωσε την καλύτερη απόδοση με ακρίβεια 95.45%. Στην κατηγορία 0, το precision ήταν 0.91 και το recall 0.99, με F1-score 0.95, δείχνοντας εξαιρετική απόδοση. Στην κατηγορία 1, το precision ήταν 0.93, αλλά το recall ήταν χαμηλότερο (0.67), κάτι που επηρέασε το F1-score (0.78). Συνολικά, το μοντέλο αποδίδει πολύ καλά, αν και θα μπορούσε να βελτιωθεί η απόδοση στην κατηγορία 1.



## 4.2 Σύγκριση μοντέλων AUC

Το KNN μοντέλο έχει  $AUC = 0.6372$ , υποδεικνύοντας χαμηλή ικανότητα διάκρισης, ιδιαίτερα στην κατηγορία 1. Το Naive Bayes βελτιώνεται με  $AUC = 0.7319$ , αλλά εξακολουθεί να έχει περιορισμούς στην κατηγορία 1. Το SVM παρουσιάζει καλή ικανότητα διάκρισης με  $AUC = 0.8317$ , ενώ η Logistic Regression με  $AUC = 0.6955$  δείχνει ότι έχει περιορισμένη απόδοση. Το Neural Network είναι το πιο αποδοτικό μοντέλο με  $AUC = 0.8431$  στο σύνολο επικύρωσης, αν και υπάρχει κάποια ένδειξη overfitting, καθώς το AUC στο σύνολο εκπαίδευσης είναι σχεδόν τέλειο (0.9988).

Συνολικά, τα Neural Network και SVM μοντέλα αποδεικνύονται τα πιο αποτελεσματικά ως προς την ικανότητα διάκρισης, ενώ το KNN και η Logistic Regression χρειάζονται βελτίωση.

## 4.3 Σύγκριση μοντέλων Confusion Matrix

Το Confusion Matrix αποτυπώνει τον αριθμό των σωστών και λανθασμένων προβλέψεων για κάθε κατηγορία, δίνοντας μια σαφή εικόνα για το πώς αποδίδουν τα μοντέλα στις κατηγορίες 0 και 1.

Στο μοντέλο KNN το confusion matrix δείχνει καλή απόδοση στην κατηγορία 0 με λίγα λάθη, αλλά στην κατηγορία 1 παρατηρούνται αρκετά False Positives και False Negatives, υποδεικνύοντας δυσκολία στη σωστή πρόβλεψη αυτής της κατηγορίας.

Το Naive Bayes μοντέλο δείχνει βελτίωση με λιγότερα False Positives στην κατηγορία 0, αλλά εξακολουθεί να εμφανίζει αρκετά False Negatives στην κατηγορία 1, κάτι που συμφωνεί με το χαμηλό precision στην κατηγορία αυτή.

Το μοντέλο SVM έχει εξαιρετική απόδοση στην κατηγορία 0, με πολύ λίγα False Positives και μόνο ελάχιστα λάθη. Ωστόσο, στην κατηγορία 1, αν και τα False Negatives είναι μειωμένα σε σχέση με άλλα μοντέλα, παραμένουν εμφανή, δείχνοντας ότι το μοντέλο δυσκολεύεται να αναγνωρίσει όλα τα θετικά παραδείγματα.

Στη Logistic Regression υπάρχουν αρκετά False Positives και False Negatives ειδικά στην κατηγορία 1, κάτι που υποδηλώνει ότι το μοντέλο έχει περιορισμένη ικανότητα στη διάκριση των θετικών παραδειγμάτων, γεγονός που επηρεάζει την ακρίβεια του.

Το Neural Network εμφανίζει την καλύτερη απόδοση στο confusion matrix, με μόνο 1 False Positive στην κατηγορία 0, ενώ υπάρχουν μερικά False Negatives στην κατηγορία 1. Αν και υπάρχουν ακόμα κάποια λάθη στην κατηγορία 1, το μοντέλο έχει συνολικά εξαιρετική απόδοση με ελάχιστα λάθη στην κατηγορία 0 και βελτιωμένη αναγνώριση των θετικών παραδειγμάτων σε σχέση με τα άλλα μοντέλα.

Συμπερασματικά, το Neural Network και το SVM έχουν την καλύτερη απόδοση ως προς το confusion matrix, με τα λιγότερα λάθη, ενώ τα KNN και Logistic Regression εμφανίζουν περισσότερα λάθη, κυρίως στην κατηγορία 1.

## 4.4 Σύγκριση με άλλες μελέτες

Παρόμοιες έρευνες έχουν γίνει, με κάποιες να αναλύουν δεδομένα από σωματοαισθητικά και κινητικά προκλητά δυναμικά (42), ηλεκτρομυογράφημα (41) και ηλεκτροεγκεφαλογράφημα (54). Στην πρώτη έρευνα δεδομένα από κινητικά προκλητά δυναμικά τεσσάρων μυών δύο άνω άκρων και δύο κατω άκρων, εκπαιδεύονται σε τρία μοντέλα μηχανικής μάθησης για την καλύτερη ταξινόμηση των μυών σε ανω και κάτω ακρα.

Το μοντέλο με την μεγαλύτερη ακρίβεια ήταν ένα μοντέλο τυχαίου δάσους (random forest) με ακρίβεια 0.97 και f1 score 0.95. Σε αυτήν την έρευνα μελετήθηκε και η ακρίβεια των νευροφυσιολόγων στην ερμηνεία των σημάτων και τα αποτελέσματα έδειξαν ότι είναι πιο χαμηλά με ακρίβεια 0.89. Στην δεύτερη έρευνα έχουμε δεδομένα από ηλεκτρομυογράφημα που εκπαιδεύονται σε διαφορετικά μοντέλα για την ταξινόμηση τους σε δύο διαφορετικά νεύρα κατά τη διάρκεια του χειρουργείου. Τα αποτελέσματα έδειξαν ότι το μοντέλο των νευρωνικών δικτύων έδωσε την μεγαλύτερη απόδοση με ακρίβεια 0.95 και f1 score 0.93. Στην τρίτη έρευνα έχουμε δεδομένα για πρόβλεψη επιληπτικής κρίσης μέσω ηλεκτροεγκεφαλογραφήματος. Εδώ τα αποτελέσματα έδειξαν ότι με την μέθοδο svm επετεύχθη ακρίβεια 100% ενώ με τα νευρωνικά δίκτυα 97%

Αυτές οι μελέτες μας δείχνουν ότι τα αποτελέσματα μας έχουν μεγάλη αξιοπιστία ως προς την ακρίβεια καθώς και το Svm και τα νευρωνικά δίκτυα έχουν πάνω από 0.90 με τα τελευταία να έχουν 0.95. Επίσης το precision είναι πολύ αξιόπιστο με 0.93 αλλά αρκετά χαμηλά βρίσκεται το recall 0,67 που χαμηλώνει έτσι το f1 score στο 0,78 τιμή που είναι επιθυμητή αλλά όχι βέλτιστη για ένα μοντέλο μηχανικής μάθησης.

## **4.5 Επιπτώσεις των ευρημάτων στην Ενδοεγχειρητική Νευροπαρακολούθηση (IONM)**

### *1. Κλινική σημασία*

Η ενσωμάτωση μοντέλων μηχανικής μάθησης (ML) στην διεγχειρητική νευροπαρακολούθηση (IONM) έχει τη δυνατότητα να βελτιώσει σημαντικά τα χειρουργικά αποτελέσματα, ιδίως σε επεμβάσεις υψηλού κινδύνου, όπως οι επεμβάσεις σπονδυλικής στήλης. Για παράδειγμα, ένα μοντέλο με υψηλή ακρίβεια θα μπορούσε να μειώσει δραματικά την εμφάνιση ψευδώς θετικών αποτελεσμάτων, αποτρέποντας έτσι περιττές χειρουργικές επεμβάσεις που θα μπορούσαν να οδηγήσουν σε επιπλοκές ή παρατεταμένους χειρουργικούς χρόνους. Αυτό είναι ιδιαίτερα σημαντικό σε χειρουργικές επεμβάσεις όπου κάθε απόφαση έχει σημαντικές συνέπειες για τη νευρολογική υγεία του ασθενούς.

Στο πλαίσιο της IONM, όπου η παρακολούθηση σε πραγματικό χρόνο είναι κρίσιμη, η υψηλή ακρίβεια εξασφαλίζει ότι οι παραγόμενες ειδοποιήσεις είναι ακριβείς, πράγμα που σημαίνει ότι όταν το μοντέλο εντοπίζει ένα πιθανό πρόβλημα, είναι πολύ πιθανό να πρόκειται για πραγματική ένδειξη νευρικού συμβιβασμού. Αυτή η αξιοπιστία μειώνει την επιβάρυνση της χειρουργικής ομάδας, επιτρέποντάς της να επικεντρωθεί σε πραγματικά κρίσιμες καταστάσεις χωρίς την απόσπαση της προσοχής από ψευδείς συναγερμούς. Κατά συνέπεια, αυτό ενισχύει την ασφάλεια των ασθενών και θα μπορούσε ενδεχομένως να μειώσει τις μετεγχειρητικές επιπλοκές που συνδέονται με νευρική βλάβη.

### *2. Εφαρμογή στην παρακολούθηση σε πραγματικό χρόνο*

Η εφαρμογή αυτών των μοντέλων ML σε IONM σε πραγματικό χρόνο δεν είναι μόνο εφικτή, αλλά θα μπορούσε επίσης να φέρει επανάσταση στον τρόπο με τον οποίο οι χειρουργικές ομάδες παρακολουθούν τη νευρική ακεραιότητα κατά τη διάρκεια των επεμβάσεων. Η ικανότητα των μοντέλων ML να επεξεργάζονται γρήγορα και με ακρίβεια τεράστιες ποσότητες νευροφυσιολογικών δεδομένων σημαίνει ότι οι αποφάσεις μπορούν να λαμβάνονται ταχύτερα και με μεγαλύτερη εμπιστοσύνη. Για παράδειγμα, εάν ένα μοντέλο διανυσματικής μηχανής υποστήριξης (SVM) εντοπίσει σημαντική πτώση στα

σωματοαισθητικά προκλητά δυναμικά (SSEP), η χειρουργική ομάδα μπορεί να ειδοποιηθεί αμέσως, επιτρέποντας την άμεση λήψη διορθωτικών μέτρων.

Αυτή η δυνατότητα πραγματικού χρόνου είναι ιδιαίτερα πολύτιμη σε πολύπλοκες χειρουργικές επεμβάσεις σπονδυλικής στήλης, όπου η έγκαιρη παρέμβαση μπορεί να είναι η διαφορά μεταξύ της διατήρησης ή της απώλειας της κινητικής ή αισθητικής λειτουργίας. Επιπλέον, η πτυχή της συνεχούς μάθησης των μοντέλων ML σημαίνει ότι μπορούν να βελτιώνονται με την πάροδο του χρόνου καθώς συγκεντρώνονται περισσότερα δεδομένα, ενισχύοντας περαιτέρω την αποτελεσματικότητα και την αξιοπιστία τους σε μελλοντικές χειρουργικές επεμβάσεις.

### *3. Τυποποίηση και αποτελεσματικότητα*

Η εφαρμογή της ML στην IONM μπορεί επίσης να οδηγήσει στην τυποποίηση των πρακτικών παρακολούθησης σε διάφορα ιδρύματα. Επί του παρόντος, υπάρχει σημαντική διακύμανση στον τρόπο ερμηνείας των δεδομένων IONM, η οποία μπορεί να οδηγήσει σε ασυνεπή αποτελέσματα για τους ασθενείς. Με την εφαρμογή τυποποιημένων μοντέλων ML, οι πάροχοι υγειονομικής περίθαλψης μπορούν να διασφαλίσουν ότι όλοι οι ασθενείς λαμβάνουν το ίδιο υψηλό επίπεδο φροντίδας, ανεξάρτητα από τον τόπο στον οποίο υποβάλλονται σε θεραπεία. Αυτή η τυποποίηση μπορεί να μειώσει την πιθανότητα ανθρώπινου λάθους και μεταβλητότητας στην ερμηνεία του σήματος, οδηγώντας σε πιο συνεπή και αξιόπιστα αποτελέσματα.

Επιπλέον, η αποτελεσματικότητα των χειρουργικών διαδικασιών μπορεί να βελτιωθεί σημαντικά. Με την αυτοματοποίηση της ανάλυσης των δεδομένων IONM, τα μοντέλα ML μπορούν να μειώσουν το χρόνο που απαιτείται για τη χειροκίνητη ερμηνεία, επιτρέποντας στις χειρουργικές ομάδες να εργάζονται πιο γρήγορα και αποτελεσματικά. Αυτό μπορεί να οδηγήσει σε συντομότερους χρόνους λειτουργίας, μειωμένη έκθεση των ασθενών σε αναισθησία και χαμηλότερες συνολικές δαπάνες υγειονομικής περίθαλψης. Η υιοθέτηση αυτών των τεχνολογιών θα μπορούσε επίσης να ανακουφίσει τους νευροφυσιολόγους, δίνοντάς τους τη δυνατότητα να επικεντρωθούν στις πιο σύνθετες περιπτώσεις όπου η τεχνογνωσία τους είναι περισσότερο απαραίτητη.

## **4.6 Περιορισμοί της μελέτης σας**

### *1. Περιορισμοί δεδομένων*

Ένας από τους πρωταρχικούς περιορισμούς της παρούσας μελέτης είναι η φύση και η ποιότητα του συνόλου δεδομένων που χρησιμοποιήθηκε. Το σύνολο δεδομένων, αν και περιεκτικό, ενδέχεται να μην αντιπροσωπεύει πλήρως την ποικιλία των νευροφυσιολογικών καταστάσεων που συναντώνται κατά τη διάρκεια της διεγχειρητικής νευροπαρακολούθησης (IONM). Το μέγεθος του συνόλου δεδομένων θα μπορούσε επίσης να αποτελέσει περιοριστικό παράγοντα, ιδίως εάν δεν υπάρχουν επαρκή παραδείγματα σπάνιων αλλά κρίσιμων νευρικών συμβάντων. Αυτός ο περιορισμός θα μπορούσε να οδηγήσει σε μοντέλα που αποδίδουν καλά υπό τυπικές συνθήκες αλλά δυσκολεύονται με ακραίες τιμές ή λιγότερο συνηθισμένα σενάρια, μειώνοντας ενδεχομένως την αξιοπιστία τους σε εφαρμογές του πραγματικού κόσμου.

Επιπλέον, η ποιότητα του συνόλου δεδομένων -όπως η παρουσία θορύβου ή ελλιπών δεδομένων- θα μπορούσε να έχει επηρεάσει τα αποτελέσματα. Για παράδειγμα, τα θορυβώδη σήματα θα μπορούσαν να έχουν υποβαθμίσει την απόδοση πιο ευαίσθητων μοντέλων, όπως τα νευρωνικά δίκτυα, οδηγώντας σε χαμηλότερη ακρίβεια ή αυξημένα ψευδώς θετικά αποτελέσματα. Αυτοί οι περιορισμοί των δεδομένων υποδηλώνουν ότι, ενώ τα μοντέλα που αναπτύχθηκαν σε αυτή τη μελέτη είναι πολλά υποσχόμενα, η γενικευσιμότητά τους σε όλα τα χειρουργικά πλαίσια μπορεί να είναι περιορισμένη.

## *2. Περιορισμοί του μοντέλου*

Κάθε μοντέλο μηχανικής μάθησης που χρησιμοποιήθηκε στην παρούσα μελέτη έχει εγγενείς περιορισμούς που θα μπορούσαν να επηρεάσουν την αποτελεσματικότητά του στην ΙΟΝΜ. Για παράδειγμα, ενώ τα Νευρωνικά Δίκτυα υπερέχουν στην αποτύπωση πολύπλοκων, μη γραμμικών σχέσεων, συχνά επικρίνονται ως "μαύρα κουτιά" λόγω της έλλειψης ερμηνευσιμότητάς τους. Αυτός ο συμβιβασμός μεταξύ ακρίβειας και ερμηνευσιμότητας είναι σημαντικός στις κλινικές ρυθμίσεις, όπου η κατανόηση της λογικής πίσω από την πρόβλεψη ενός μοντέλου είναι ζωτικής σημασίας για την απόκτηση της εμπιστοσύνης των χειρουργών και των νευροφυσιολόγων.

Επιπλέον, απλούστερα μοντέλα όπως η λογιστική παλινδρόμηση, ενώ είναι πιο ερμηνεύσιμα, μπορεί να δυσκολεύονται να συλλάβουν τα περίπλοκα μοτίβα στα νευροφυσιολογικά δεδομένα, οδηγώντας ενδεχομένως σε χαμηλότερη ακρίβεια στην ανίχνευση λεπτών νευρικών συμβάντων. Το μοντέλο Naïve Bayes, το οποίο υποθέτει ανεξαρτησία μεταξύ των χαρακτηριστικών, ενδέχεται να μην καταγράφει πλήρως τις εξαρτήσεις που υπάρχουν στα πολύπλοκα δεδομένα ΙΟΝΜ, οδηγώντας σε μη βέλτιστες επιδόσεις σε ορισμένες περιπτώσεις.

## *3. Τεχνικοί περιορισμοί*

Οι τεχνικές προκλήσεις έθεσαν επίσης σημαντικούς περιορισμούς στην παρούσα μελέτη. Οι υπολογιστικοί πόροι που απαιτούνται για την εκπαίδευση και την επικύρωση σύνθετων μοντέλων όπως τα Νευρωνικά Δίκτυα ήταν σημαντικοί, ιδίως κατά τη ρύθμιση των υπερπαραμέτρων και τη διεξαγωγή διασταυρούμενης επικύρωσης. Αυτός ο περιορισμός περιόρισε το πεδίο πειραματισμού, οδηγώντας ενδεχομένως σε λιγότερο βελτιστοποιημένα μοντέλα. Σε κλινικά περιβάλλοντα πραγματικού χρόνου, αυτές οι υπολογιστικές απαιτήσεις θα μπορούσαν να εμποδίσουν την πρακτική ανάπτυξη τέτοιων μοντέλων, ιδίως σε περιβάλλοντα με περιορισμένους πόρους.

Επιπλέον, η εφαρμογή αυτών των μοντέλων σε ένα σύστημα ΙΟΝΜ σε πραγματικό χρόνο παρουσιάζει προκλήσεις. Η ανάγκη ταχείας επεξεργασίας δεδομένων και λήψης αποφάσεων σημαίνει ότι τα μοντέλα πρέπει να είναι όχι μόνο ακριβή αλλά και αποτελεσματικά. Η ισορροπία μεταξύ ταχύτητας και ακρίβειας είναι λεπτή- τα μοντέλα που είναι πολύ αργά μπορεί να μην είναι χρησιμοποιήσιμα στο ταχύτατο περιβάλλον μιας χειρουργικής αίθουσας, ενώ τα υπερβολικά απλοποιημένα μοντέλα μπορεί να μην παρέχουν την απαραίτητη αξιοπιστία.

## 4.7 Πιθανές βελτιώσεις και μελλοντικές εργασίες

### 1. Βελτιώσεις μοντέλου

Για να βελτιωθεί η απόδοση του μοντέλου, οι μελλοντικές εργασίες θα πρέπει να διερευνήσουν ένα ευρύτερο φάσμα αλγορίθμων μηχανικής μάθησης, συμπεριλαμβανομένων μεθόδων συνόλου, όπως τα τυχαία δάση τα οποία θα μπορούσαν ενδεχομένως να συλλάβουν πιο σύνθετα μοτίβα στα δεδομένα διεγχειρητικής νευροφυσιολογικής παρακολούθησης (IONM). Επιπλέον, η βελτίωση των υπερπαραμέτρων μέσω πιο προηγμένων τεχνικών, όπως η βελτιστοποίηση κατά Bayes, θα μπορούσε να βελτιώσει περαιτέρω την ακρίβεια και την ευελιξία του μοντέλου. Η ενσωμάτωση προηγμένων τεχνικών προεπεξεργασίας δεδομένων, όπως η επιλογή χαρακτηριστικών ή η μείωση της διαστατικότητας, μπορεί επίσης να συμβάλει στη μείωση του θορύβου και στη βελτίωση της ερμηνευσιμότητας και της αποτελεσματικότητας του μοντέλου.

### 2. Διευρυμένες εφαρμογές

Πέρα από την τρέχουσα εφαρμογή στις χειρουργικές επεμβάσεις σπονδυλικής στήλης και εγκεφάλου, τα μοντέλα που αναπτύχθηκαν στην παρούσα μελέτη θα μπορούσαν να επεκταθούν σε άλλους τύπους χειρουργικών επεμβάσεων όπου η IONM είναι κρίσιμη, όπως καρδιαγγειακές επεμβάσεις. Οι μελλοντικές εργασίες θα μπορούσαν επίσης να διερευνήσουν την πολυτροπική παρακολούθηση, όπου τα δεδομένα από διαφορετικούς τύπους νευροφυσιολογικών σημάτων (π.χ. EEG, EMG, SSEPs και MEPs) ενσωματώνονται και αναλύονται μαζί για να παρέχουν μια πιο ολοκληρωμένη εικόνα της νευρικής λειτουργίας του ασθενούς κατά τη διάρκεια της χειρουργικής επέμβασης. Οι εξατομικευμένες στρατηγικές παρακολούθησης που προσαρμόζονται στα ατομικά χαρακτηριστικά του ασθενούς θα μπορούσαν να βελτιώσουν περαιτέρω την ακρίβεια και την αποτελεσματικότητα της IONM.

### 3. Μακροπρόθεσμες ερευνητικές κατευθύνσεις

Η μελλοντική έρευνα θα πρέπει να επικεντρωθεί στη διεξαγωγή εκτεταμένων κλινικών δοκιμών για την επικύρωση της αποτελεσματικότητας αυτών των μοντέλων σε πραγματικές χειρουργικές ρυθμίσεις. Αυτό θα περιλαμβάνει τη συνεργασία με χειρουργικές ομάδες για την εφαρμογή των μοντέλων στα χειρουργεία και την αξιολόγηση των επιπτώσεών τους στα αποτελέσματα των ασθενών. Επιπλέον, η ενσωμάτωση πιο προηγμένων τεχνικών μηχανικής μάθησης, όπως η βαθιά μάθηση ή η ενισχυτική μάθηση, θα μπορούσε να ανοίξει νέους δρόμους για αυτοματοποιημένη λήψη αποφάσεων σε πραγματικό χρόνο κατά τη διάρκεια της χειρουργικής επέμβασης. Η ανάπτυξη εργαλείων παρακολούθησης σε πραγματικό χρόνο που θα είναι φιλικά προς τον χρήστη και θα ενσωματώνονται απρόσκοπτα στις υπάρχουσες χειρουργικές ροές εργασίας θα είναι ζωτικής σημασίας για την πρακτική υιοθέτηση αυτών των τεχνολογιών στην κλινική πρακτική.

## 5 Επίλογος

Η παρούσα διατριβή κατέδειξε τις σημαντικές δυνατότητες των μοντέλων μηχανικής μάθησης (ML) στην ενίσχυση της διεγχειρητικής νευροπαρακολούθησης (IONM) με την ακριβή ταξινόμηση και ανάλυση νευροφυσιολογικών σημάτων. Μεταξύ των μοντέλων που δοκιμάστηκαν, ο αλγόριθμος νευρωνικού δικτύου, σε συνδυασμό με προηγμένες τεχνικές επιλογής χαρακτηριστικών, αναδείχθηκε ως ο πιο αποτελεσματικός, επιτυγχάνοντας ανώτερη ακρίβεια, precision, ανάκληση και F1-score σε σύγκριση με τις παραδοσιακές μεθόδους. Τα ευρήματα αυτά υπογραμμίζουν την ικανότητα της ενισχυμένης με ML IONM να μειώσει τη συχνότητα εμφάνισης μετεγχειρητικών νευρολογικών ελλειμμάτων, προσφέροντας ακριβείς εκτιμήσεις σε πραγματικό χρόνο κατά τη διάρκεια της χειρουργικής επέμβασης.

Οι συνέπειες αυτής της έρευνας για τη χειρουργική πρακτική είναι βαθιές. Με την ενσωμάτωση του ML στην IONM, οι επαγγελματίες του τομέα της υγειονομικής περίθαλψης μπορούν να λαμβάνουν πιο τεκμηριωμένες αποφάσεις με βάση τα δεδομένα στο χειρουργείο, ενισχύοντας τελικά την ασφάλεια των ασθενών και βελτιώνοντας τα χειρουργικά αποτελέσματα. Ωστόσο, η μελέτη αυτή αντιμετώπισε επίσης περιορισμούς, συμπεριλαμβανομένης της ανάγκης για μεγαλύτερα σύνολα δεδομένων και της πρόκλησης της γενίκευσης των μοντέλων σε διαφορετικά χειρουργικά πλαίσια. Η μελλοντική έρευνα θα πρέπει να διερευνήσει την εφαρμογή πιο εξελιγμένων μοντέλων βαθιάς μάθησης και την ενσωμάτωση της ML με αναδυόμενες τεχνολογίες, όπως η επαυξημένη πραγματικότητα και η ρομποτική.

Συμπερασματικά, η παρούσα έρευνα συμβάλλει στον αυξανόμενο όγκο στοιχείων που υποστηρίζουν τη χρήση της μηχανικής μάθησης στη χειρουργική περίθαλψη. Καθώς ο τομέας συνεχίζει να εξελίσσεται, η υιοθέτηση της ML στην IONM θα μπορούσε να αποτελέσει ακρογωνιαίο λίθο της σύγχρονης χειρουργικής πρακτικής, προσφέροντας ένα ισχυρό εργαλείο για τη βελτίωση της ακρίβειας, της αποτελεσματικότητας και της ασφάλειας των χειρουργικών επεμβάσεων παγκοσμίως.

## Βιβλιογραφία

1. Tamaki T, Kubota S. History of the development of intraoperative spinal cord monitoring. *Eur Spine J*. 2007 Nov;16(S2):140–6.
2. Abouzeid W, Abdel Tawab M, Hanna B, Niazy T, Hussein S, Almamoun M. Impact of Intraoperative Neurophysiological Monitoring on the Extent of Resection and Postoperative Neurological Outcomes in Patients with Spinal Cord Ependymoma: A Retrospective Multicenter Comparative Study. *Egyptian Spine Journal*. 2021 Jul 1;39(1):29–45.
3. Nuwer MR, Husain AM, Soto F. Overview of intraoperative neuromonitoring. *Handb Clin Neurol*. 2022;186:3–9.
4. Badillo S, Banfai B, Birzele F, Davydov II, Hutchinson L, Kam-Thong T, et al. An Introduction to Machine Learning. *Clin Pharma and Therapeutics*. 2020 Apr;107(4):871–85.
5. Kumar I, Singh SP, Shivam. Machine learning in bioinformatics. In: *Bioinformatics [Internet]*. Elsevier; 2022 [cited 2024 Oct 10]. p. 443–56. Available from: <https://linkinghub.elsevier.com/retrieve/pii/B9780323897754000201>
6. Rafid Siddiqui, PhD, . ML Basics (Part-1): REGRESSION — A Gateway Method to Machine Learning.
7. Support Vector Machine Algorithm.
8. Artificial Neural Networks and its Applications. *geeksforgeeks*. 2024.
9. ali moosa. Implementing K-Means Clustering with K-Means++ Initialization in Python. 2021.
10. An Q, Rahman S, Zhou J, Kang JJ. A Comprehensive Review on Machine Learning in Healthcare Industry: Classification, Restrictions, Opportunities and Challenges. *Sensors (Basel)*. 2023 Apr 22;23(9):4178.
11. Dixon MF, Halperin I, Bilokon P. Machine Learning in Finance: From Theory to Practice [Internet]. Cham: Springer International Publishing; 2020 [cited 2024 Aug 27]. Available from: <http://link.springer.com/10.1007/978-3-030-41068-1>
12. Kumar MR, Venkatesh J, Rahman AMJMZ. Data mining and machine learning in retail business: developing efficiencies for better customer retention. *J Ambient Intell Human Comput [Internet]*. 2021 Jan 2 [cited 2024 Aug 27]; Available from: <http://link.springer.com/10.1007/s12652-020-02711-7>
13. Bertolini M, Mezzogori D, Neroni M, Zammori F. Machine Learning for industrial applications: A comprehensive literature review. *Expert Systems with Applications*. 2021 Aug;175:114820.
14. Soni A, Dharmacharya D, Pal A, Srivastava VK, Shaw RN, Ghosh A. Design of a Machine Learning-Based Self-driving Car. In: Bianchini M, Simic M, Ghosh A, Shaw RN, editors.

- Machine Learning for Robotics Applications [Internet]. Singapore: Springer Singapore; 2021 [cited 2024 Aug 27]. p. 139–51. (Studies in Computational Intelligence; vol. 960). Available from: [https://link.springer.com/10.1007/978-981-16-0598-7\\_11](https://link.springer.com/10.1007/978-981-16-0598-7_11)
15. Nagarhalli TP, Vaze V, Rana NK. Impact of Machine Learning in Natural Language Processing: A Review. In: 2021 Third International Conference on Intelligent Communication Technologies and Virtual Mobile Networks (ICICV) [Internet]. Tirunelveli, India: IEEE; 2021 [cited 2024 Aug 27]. p. 1529–34. Available from: <https://ieeexplore.ieee.org/document/9388380/>
  16. Tragaris T, Benetos IS, Vlamis J, Pneumaticos S. Machine Learning Applications in Spine Surgery. *Cureus*. 2023 Oct;15(10):e48078.
  17. Somatosensory Evoked Potentials (SSEP). In: neurophyspedia.
  18. Linden RD, Zhang YP, Burke DA, Hunt MA, Harpring JE, Shields CB. Magnetic motor evoked potential monitoring in the rat. *Journal of Neurosurgery: Spine*. 1999 Oct;91(2):205–10.
  19. Park SK. Intraoperative Neurophysiological Monitoring in Cerebello Pontine Angle Tumor. *Korean J Clin Lab Sci*. 2014 Mar 31;46(1):38–45.
  20. brigham and womens hospital. INTRAOPERATIVE NEUROMONITORING.
  21. Legatt AD. Electrophysiologic auditory tests. In: Handbook of Clinical Neurology [Internet]. Elsevier; 2015 [cited 2024 Oct 10]. p. 289–311. Available from: <https://linkinghub.elsevier.com/retrieve/pii/B9780444626301000172>
  22. Thirumala PD, Kodavatiganti HS, Habeych M, Wichman K, Chang Y fang, Gardner P, et al. Value of multimodality monitoring using brainstem auditory evoked potentials and somatosensory evoked potentials in endoscopic endonasal surgery. *Neurological Research*. 2013 Jul;35(6):622–30.
  23. Zelenski NA, Oishi T, Shin AY. Intraoperative Neuromonitoring for Peripheral Nerve Surgery. *J Hand Surg Am*. 2023 Apr;48(4):396–401.
  24. Tao X, Fan X, Gui S, Liu J, Yang X, Li K, et al. Efficacy of intraoperative visual evoked potential amplitude reduction in predicting visual outcome after extended endoscopic endonasal resection of craniopharyngiomas. *Journal of Neurosurgery*. 2024 May 1;140(5):1270–5.
  25. Ghadirpour R, Nasi D, Iaccarino C, Romano A, Motti L, Sabadini R, et al. Intraoperative neurophysiological monitoring for intradural extramedullary spinal tumors: predictive value and relevance of D-wave amplitude on surgical outcome during a 10-year experience. *Journal of Neurosurgery: Spine*. 2019 Feb;30(2):259–67.
  26. Wu J, Hicks C. Breast Cancer Type Classification Using Machine Learning. *JPM*. 2021 Jan 20;11(2):61.



27. Tanveer M, Richhariya B, Khan RU, Rashid AH, Khanna P, Prasad M, et al. Machine Learning Techniques for the Diagnosis of Alzheimer’s Disease: A Review. *ACM Trans Multimedia Comput Commun Appl.* 2020 Jan 31;16(1s):1–35.
28. Henglin M, Stein G, Hushcha PV, Snoek J, Wiltschko AB, Cheng S. Machine Learning Approaches in Cardiovascular Imaging. *Circ: Cardiovascular Imaging.* 2017 Oct;10(10):e005614.
29. Tong Y, Lu W, Yu Y, Shen Y. Application of machine learning in ophthalmic imaging modalities. *Eye and Vis.* 2020 Dec;7(1):22.
30. Cabitza F, Locoro A, Banfi G. Machine Learning in Orthopedics: A Literature Review. *Front Bioeng Biotechnol.* 2018 Jun 27;6:75.
31. Giger ML. Machine Learning in Medical Imaging. *Journal of the American College of Radiology.* 2018 Mar;15(3):512–20.
32. Choudhury A, Gupta D. A Survey on Medical Diagnosis of Diabetes Using Machine Learning Techniques. In: Kalita J, Balas VE, Borah S, Pradhan R, editors. *Recent Developments in Machine Learning and Data Analytics [Internet].* Singapore: Springer Singapore; 2019 [cited 2024 Aug 27]. p. 67–78. (Advances in Intelligent Systems and Computing; vol. 740). Available from: [http://link.springer.com/10.1007/978-981-13-1280-9\\_6](http://link.springer.com/10.1007/978-981-13-1280-9_6)
33. Kannan R, Vasanthi V. Machine Learning Algorithms with ROC Curve for Predicting and Diagnosing the Heart Disease. In: *Soft Computing and Medical Bioinformatics [Internet].* Singapore: Springer Singapore; 2019 [cited 2024 Aug 27]. p. 63–72. (SpringerBriefs in Applied Sciences and Technology). Available from: [http://link.springer.com/10.1007/978-981-13-0059-2\\_8](http://link.springer.com/10.1007/978-981-13-0059-2_8)
34. Qaid TS, Mazaar H, Al-Shamri MYH, Alqahtani MS, Raweh AA, Alakwaa W. Hybrid Deep-Learning and Machine-Learning Models for Predicting COVID-19. Yáñez-Márquez C, editor. *Computational Intelligence and Neuroscience.* 2021 Jan;2021(1):9996737.
35. Libbrecht MW, Noble WS. Machine learning applications in genetics and genomics. *Nat Rev Genet.* 2015 Jun;16(6):321–32.
36. Moon I, LoPiccolo J, Baca SC, Sholl LM, Kehl KL, Hassett MJ, et al. Machine learning for genetics-based classification and treatment response prediction in cancer of unknown primary. *Nat Med.* 2023 Aug;29(8):2057–67.
37. Kalinin AA, Higgins GA, Reamaroon N, Soroushmehr S, Allyn-Feuer A, Dinov ID, et al. Deep Learning in Pharmacogenomics: From Gene Regulation to Patient Stratification. *Pharmacogenomics.* 2018 May;19(7):629–50.
38. Pati J. Gene Expression Analysis for Early Lung Cancer Prediction Using Machine Learning Techniques: An Eco-Genomics Approach. *IEEE Access.* 2019;7:4232–8.

39. Wilson JP, Kumbhare D, Ronkon C, Guthikonda B, Hoang S. Application of Machine Learning Strategies to Model the Effects of Sevoflurane on Somatosensory-Evoked Potentials during Spine Surgery. *Diagnostics*. 2023 Nov 6;13(21):3389.
40. Park D, Kim I. Application of Machine Learning in the Field of Intraoperative Neurophysiological Monitoring: A Narrative Review. *Applied Sciences*. 2022 Aug 8;12(15):7943.
41. Jiang W, Zhan Q, Wang J, Wei M, Li S, Mei R, et al. Quantitative identification of ventral/dorsal nerves through intraoperative neurophysiological monitoring by supervised machine learning. *Front Pediatr*. 2023 May 18;11:1118924.
42. Wermelinger J, Parduzi Q, Sariyar M, Raabe A, Schneider UC, Seidel K. Opportunities and challenges of supervised machine learning for the classification of motor evoked potentials according to muscles. *BMC Med Inform Decis Mak*. 2023 Oct 2;23(1):198.
43. Ma W. A Multichannel Continuous Clinical Electromyography Dataset from Neurosurgery [Internet]. Mendeley Data; 2024 [cited 2024 Aug 8]. Available from: <https://data.mendeley.com/datasets/7hyptcbkdd/2>
44. Ma W, Chen L, Pang X, Zou Y. A multichannel electromyography dataset for continuous intraoperative neurophysiological monitoring of cranial nerve. *Data in Brief*. 2024 Apr;53:110250.
45. Toledo-Perez DC, Rodriguez-Resendiz J, Gomez-Loenzo RA. A Study of Computing Zero Crossing Methods and an Improved Proposal for EMG Signals. *IEEE Access*. 2020;8:8783–90.
46. Waris A, Kamavuako EN. Effect of threshold values on the combination of EMG time domain features: Surface versus intramuscular EMG. *Biomedical Signal Processing and Control*. 2018 Aug;45:267–73.
47. Dong Y, Li B, Hu J, Widmalm SE, Zhang T, Lin M, et al. Kurtosis, a new variable with possible diagnostic value in analysis of jaw muscle surface EMG. *J of Oral Rehabilitation*. 2022 Feb;49(2):170–6.
48. Eskov VM, Eskov VV, Vochmina YuV, Gorbunov DV, Ilyashenko LK. Shannon entropy in the research on stationary regimes and the evolution of complexity. *Moscow Univ Phys*. 2017 May;72(3):309–17.
49. Rautee R, Sampson T, Sarkela M, Melto S, Hovilehto S, Van Gils M. Application of spectral entropy to EEG and facial EMG frequency bands for the assessment of level of sedation in ICU. In: *The 26th Annual International Conference of the IEEE Engineering in Medicine and Biology Society* [Internet]. San Francisco, CA, USA: IEEE; 2004 [cited 2024 Aug 27]. p. 3481–4. Available from: <http://ieeexplore.ieee.org/document/1403977/>
50. St»hle L, Wold S. Analysis of variance (ANOVA). *Chemometrics and Intelligent Laboratory Systems*. 1989 Nov;6(4):259–72.

51. Browne MW. Cross-Validation Methods. *Journal of Mathematical Psychology*. 2000 Mar;44(1):108–32.
52. Huang Y, Bao Y, Petropoulos GP, Lu Q, Huo Y, Wang F. Precipitation Estimation Using FY-4B/AGRI Satellite Data Based on Random Forest. *Remote Sensing*. 2024 Apr 3;16(7):1267.
53. Suwardi, Sutiarso L, Wirianata H, Nugroho AP, Sukarman, Primananda S, et al. Optimization of a soil type prediction method based on the deep learning model and vegetation characteristics. *Plant Sci Today* [Internet]. 2023 Dec 31 [cited 2024 Oct 10]; Available from: <https://horizonepublishing.com/journals/index.php/PST/article/view/2926>
54. Saeidi M, Karwowski W, Farahani FV, Fiok K, Taiar R, Hancock PA, et al. Neural Decoding of EEG Signals with Machine Learning: A Systematic Review. *Brain Sciences*. 2021 Nov 18;11(11):1525.

## Παράρτημα - Κώδικας

Απόσπασμα κώδικα Α.1: Επεξεργασία και εξαγωγή χαρακτηριστικών

```
import pandas as pd
import numpy as np
from scipy.stats import skew, kurtosis, entropy
from scipy.signal import welch

def zero_crossings(signal):
    return ((signal[:-1] * signal[1:]) < 0).sum()

def slope_sign_changes(signal, threshold=0.001):
    return ((signal[:-2] < signal[1:-1]) & (signal[1:-1] > signal[2:])) |
    (signal[:-2] > signal[1:-1]) & (signal[1:-1] < signal[2:])).sum()

def waveform_length(signal):
    return np.sum(np.abs(np.diff(signal)))

def shannon_entropy(signal):
    hist, _ = np.histogram(signal, bins=64, density=True)
    return entropy(hist)

def spectral_entropy(signal, sf=1000):
    freqs, psd = welch(signal, sf)
    psd /= psd.sum() # Normalize the power spectrum
    return entropy(psd)

# Load the CSV file
latest_data_path = '/content/11.csv'
latest_data = pd.read_csv(latest_data_path)

# Drop unnecessary label columns and rename the timestamp column
latest_data_clean = latest_data.drop(columns=['VII_label', 'VII.1_label',
'V_label', 'XI_label', 'X_label', 'XII_label', 'label'])
latest_data_clean.rename(columns={'Unnamed: 0': 'timestamp'},
inplace=True)

# Calculate features for each segment and channel
features_list = []

for segment_name, group in latest_data_clean.groupby('segment_id'):
    features = {
        'segment_id': segment_name,
        'patient_id': group['patient_id'].iloc[0]
    }
    for channel in ['VII', 'VII.1', 'V', 'XI', 'X', 'XII']:
        signal = group[channel].values
        features[f'{channel}_Mean_Abs_Value'] = np.mean(np.abs(signal))
        features[f'{channel}_Zero_Crossings'] = zero_crossings(signal)
        features[f'{channel}_Slope_Sign_Changes'] =
slope_sign_changes(signal)
        features[f'{channel}_Waveform_Length'] = waveform_length(signal)
        features[f'{channel}_Std_Dev'] = np.std(signal)
        features[f'{channel}_Skewness'] = skew(signal)
        features[f'{channel}_Kurtosis'] = kurtosis(signal)
        features[f'{channel}_Shannon_Entropy'] = shannon_entropy(signal)
        features[f'{channel}_Spectral_Entropy'] = spectral_entropy(signal)
    features_list.append(features)

# Convert features to DataFrame and save to CSV
features_df = pd.DataFrame(features_list)
features_df.to_csv('/content/untitled', index=False)
```

## Απόσπασμα κώδικα Α.2: Μοντέλο knn

```
import numpy as np
import pandas as pd
from sklearn.preprocessing import StandardScaler
from imblearn.over_sampling import RandomOverSampler
from sklearn.model_selection import cross_val_score, train_test_split,
GridSearchCV
from sklearn.neighbors import KNeighborsClassifier
from sklearn.metrics import classification_report, roc_curve, auc,
confusion_matrix, ConfusionMatrixDisplay
from sklearn.feature_selection import SelectKBest, f_classif
import matplotlib.pyplot as plt

# Load the dataset
df = pd.read_excel("/content/emg_feature_data.xlsx")

# Split the dataset into training, validation, and test sets
train, valid, test = np.split(df.sample(frac=1, random_state=42),
[int(0.6*len(df)), int(0.8*len(df))])

# Function to scale datasets
def scale_dataset(dataframe, oversample=False):
    # Separate features and target variable
    x = dataframe[dataframe.columns[:-1]].values
    y = dataframe[dataframe.columns[-1]].values

    # Scale features
    scaler = StandardScaler()
    x = scaler.fit_transform(x)

    # Oversample the minority class if specified
    if oversample:
        ros = RandomOverSampler(random_state=42)
        x, y = ros.fit_resample(x, y)

    # Combine features and target variable
    data = np.hstack((x, np.reshape(y, (-1, 1))))

    return data, x, y

# Scale the datasets
train_scaled, x_train, y_train = scale_dataset(train, oversample=True)
valid_scaled, x_valid, y_valid = scale_dataset(valid, oversample=False)
test_scaled, x_test, y_test = scale_dataset(test, oversample=False)

# Select top 5 features using ANOVA F-test
selector = SelectKBest(f_classif, k=3)
x_train_best = selector.fit_transform(x_train, y_train)
x_valid_best = selector.transform(x_valid)
x_test_best = selector.transform(x_test)
selected_features = selector.get_support(indices=True)
best_features = df.columns[selected_features]

# Define parameter grid for KNN
param_grid = {
    'n_neighbors': [3, 5, 7, 9],
    'weights': ['uniform', 'distance'],
    'metric': ['euclidean', 'manhattan']
}
```

Ο ΡΟΛΟΣ ΤΗΣ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ ΣΤΗΝ ΠΡΟΒΛΕΨΗ ΝΕΥΡΟΛΟΓΙΚΩΝ ΑΠΟΤΕΛΕΣΜΑΤΩΝ ΑΠΟ  
ΔΕΔΟΜΕΝΑ ΕΝΔΟΕΓΧΕΙΡΗΤΙΚΗΣ ΝΕΥΡΟΠΑΡΑΚΟΛΟΥΘΗΣΗΣ

```
# Perform grid search with cross-validation
knn = KNeighborsClassifier()
grid_search = GridSearchCV(knn, param_grid, cv=5, n_jobs=-1,
scoring='accuracy')
grid_search.fit(x_train_best, y_train)

# Get the best model
best_model = grid_search.best_estimator_
best_params = grid_search.best_params_
best_accuracy = grid_search.best_score_

print(f"Best Features: {best_features}, Best Params: {best_params},
Accuracy: {best_accuracy:.4f}")

# Validate the best model on the validation set
y_pred = best_model.predict(x_valid_best)

# Print classification report
report = classification_report(y_valid, y_pred)
print("Classification Report:\n", report)

# Calculate ROC curve and AUC for the validation set
y_prob = best_model.predict_proba(x_valid_best)[: , 1] # Get probability
estimates for the positive class
fpr, tpr, _ = roc_curve(y_valid, y_prob)
roc_auc = auc(fpr, tpr)

# Plot the ROC curve
plt.figure()
plt.plot(fpr, tpr, color='darkorange', lw=2, label=f'ROC curve (AUC =
{roc_auc:.4f})')
plt.plot([0, 1], [0, 1], color='navy', lw=2, linestyle='--')
plt.xlim([0.0, 1.0])
plt.ylim([0.0, 1.05])
plt.xlabel('False Positive Rate')
plt.ylabel('True Positive Rate')
plt.title('Receiver Operating Characteristic')
plt.legend(loc="lower right")
plt.show()

# Print confusion matrix
conf_matrix = confusion_matrix(y_valid, y_pred)
disp = ConfusionMatrixDisplay(confusion_matrix=conf_matrix)
disp.plot()
plt.title("Confusion Matrix")
plt.show()

# Print ROC AUC
print(f"AUC (ROC): {roc_auc:.4f}")
```

**Απόσπασμα κώδικα Α.3: Μοντέλο Naïve Bayes**

```
import numpy as np
import pandas as pd
from sklearn.preprocessing import StandardScaler
from imblearn.over_sampling import RandomOverSampler
from sklearn.model_selection import cross_val_score, StratifiedKFold,
train_test_split
from sklearn.naive_bayes import GaussianNB
```

Ο ΡΟΛΟΣ ΤΗΣ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ ΣΤΗΝ ΠΡΟΒΛΕΨΗ ΝΕΥΡΟΛΟΓΙΚΩΝ ΑΠΟΤΕΛΕΣΜΑΤΩΝ ΑΠΟ  
ΔΕΔΟΜΕΝΑ ΕΝΔΟΕΓΧΕΙΡΗΤΙΚΗΣ ΝΕΥΡΟΠΑΡΑΚΟΛΟΥΘΗΣΗΣ

```
from sklearn.metrics import classification_report, roc_curve, auc,
confusion_matrix, ConfusionMatrixDisplay
from sklearn.feature_selection import SelectKBest, f_classif
import matplotlib.pyplot as plt

# Load the dataset
df = pd.read_excel("/content/emg_feature_data.xlsx")

# Split the dataset into training and test sets (since we'll use cross-
validation)
train, test = train_test_split(df, test_size=0.2, random_state=42)

# Function to scale datasets
def scale_dataset(dataframe, oversample=False):
    # Separate features and target variable
    x = dataframe[dataframe.columns[:-1]].values
    y = dataframe[dataframe.columns[-1]].values

    # Scale features
    scaler = StandardScaler()
    x = scaler.fit_transform(x)

    # Oversample the minority class if specified
    if oversample:
        ros = RandomOverSampler(random_state=42)
        x, y = ros.fit_resample(x, y)

    return x, y

# Scale the datasets
x_train, y_train = scale_dataset(train, oversample=True)
x_test, y_test = scale_dataset(test, oversample=False)

# Select top 3 features using ANOVA F-test
selector = SelectKBest(f_classif, k=3)
x_train_best = selector.fit_transform(x_train, y_train)
x_test_best = selector.transform(x_test)
selected_features = selector.get_support(indices=True)
best_features = df.columns[selected_features]

# Define the Naive Bayes model
nb = GaussianNB()

# Perform cross-validation using Stratified K-Folds
cv = StratifiedKFold(n_splits=5)
cv_scores = cross_val_score(nb, x_train_best, y_train, cv=cv,
scoring='accuracy')

# Print cross-validation results
print(f"Cross-validation scores: {cv_scores}")
print(f"Mean CV Accuracy: {np.mean(cv_scores):.4f}")
print(f"Standard Deviation of CV Accuracy: {np.std(cv_scores):.4f}")

# Train the model on the full training set (after cross-validation)
nb.fit(x_train_best, y_train)

# Validate the model on the test set
y_pred = nb.predict(x_test_best)

# Print classification report
report = classification_report(y_test, y_pred)
print("Best Features:", best_features)
print("Classification Report:\n", report)
```

Ο ΡΟΛΟΣ ΤΗΣ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ ΣΤΗΝ ΠΡΟΒΛΕΨΗ ΝΕΥΡΟΛΟΓΙΚΩΝ ΑΠΟΤΕΛΕΣΜΑΤΩΝ ΑΠΟ  
ΔΕΔΟΜΕΝΑ ΕΝΔΟΕΓΧΕΙΡΗΤΙΚΗΣ ΝΕΥΡΟΠΑΡΑΚΟΛΟΥΘΗΣΗΣ

```
# Calculate ROC curve and AUC for the test set
y_prob = nb.predict_proba(x_test_best)[: , 1] # Get probability estimates
for the positive class
fpr, tpr, _ = roc_curve(y_test, y_prob)
roc_auc = auc(fpr, tpr)

# Plot the ROC curve
plt.figure()
plt.plot(fpr, tpr, color='darkorange', lw=2, label=f'ROC curve (AUC =
{roc_auc:.4f})')
plt.plot([0, 1], [0, 1], color='navy', lw=2, linestyle='--')
plt.xlim([0.0, 1.0])
plt.ylim([0.0, 1.05])
plt.xlabel('False Positive Rate')
plt.ylabel('True Positive Rate')
plt.title('Receiver Operating Characteristic')
plt.legend(loc="lower right")
plt.show()

# Print confusion matrix
conf_matrix = confusion_matrix(y_test, y_pred)
disp = ConfusionMatrixDisplay(confusion_matrix=conf_matrix)
disp.plot()
plt.title("Confusion Matrix")
plt.show()

# Print ROC AUC
print(f"AUC (ROC): {roc_auc:.4f}")
```

**Απόσπασμα κώδικα Α.4: Μοντέλο Logistic Regression**

```
import numpy as np
import pandas as pd
from sklearn.preprocessing import StandardScaler
from imblearn.over_sampling import RandomOverSampler
from sklearn.model_selection import train_test_split, GridSearchCV
from sklearn.linear_model import LogisticRegression
from sklearn.metrics import classification_report, roc_curve, auc,
confusion_matrix, ConfusionMatrixDisplay
from sklearn.feature_selection import SelectKBest, f_classif
import matplotlib.pyplot as plt

# Load the dataset
df = pd.read_excel("/content/emg_feature_data.xlsx")

# Split the dataset into training, validation, and test sets
train, valid, test = np.split(df.sample(frac=1, random_state=42),
[int(0.6*len(df)), int(0.8*len(df))])

# Function to scale datasets
def scale_dataset(dataframe, oversample=False):
    # Separate features and target variable
    x = dataframe[dataframe.columns[:-1]].values
    y = dataframe[dataframe.columns[-1]].values

    # Scale features
    scaler = StandardScaler()
    x = scaler.fit_transform(x)

    # Oversample the minority class if specified
```



Ο ΡΟΛΟΣ ΤΗΣ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ ΣΤΗΝ ΠΡΟΒΛΕΨΗ ΝΕΥΡΟΛΟΓΙΚΩΝ ΑΠΟΤΕΛΕΣΜΑΤΩΝ ΑΠΟ  
ΔΕΔΟΜΕΝΑ ΕΝΔΟΕΓΧΕΙΡΗΤΙΚΗΣ ΝΕΥΡΟΠΑΡΑΚΟΛΟΥΘΗΣΗΣ

```
if oversample:
    ros = RandomOverSampler(random_state=42)
    x, y = ros.fit_resample(x, y)

return x, y

# Scale the datasets
x_train, y_train = scale_dataset(train, oversample=True)
x_valid, y_valid = scale_dataset(valid, oversample=False)
x_test, y_test = scale_dataset(test, oversample=False)

# Select top 9 features using ANOVA F-test
selector = SelectKBest(f_classif, k=9)
x_train_best = selector.fit_transform(x_train, y_train)
x_valid_best = selector.transform(x_valid)
x_test_best = selector.transform(x_test)
selected_features = selector.get_support(indices=True)
best_features = df.columns[selected_features]

# Define parameter grid for Logistic Regression
param_grid = {
    'penalty': ['l1', 'l2', 'elasticnet', 'none'],
    'C': [0.01, 0.1, 1, 10, 100],
    'solver': ['newton-cg', 'lbfgs', 'liblinear', 'sag', 'saga'],
    'max_iter': [100, 200, 300]
}

# Perform grid search with cross-validation
log_reg = LogisticRegression()
grid_search = GridSearchCV(log_reg, param_grid, cv=5, n_jobs=-1,
scoring='accuracy')
grid_search.fit(x_train_best, y_train)

# Get the best model
best_model = grid_search.best_estimator_
best_params = grid_search.best_params_
best_accuracy = grid_search.best_score_

print(f"Best Features: {best_features}, Best Params: {best_params},
Accuracy: {best_accuracy:.4f}")

# Validate the best model on the validation set
y_pred = best_model.predict(x_valid_best)

# Print classification report
report = classification_report(y_valid, y_pred)
print("Classification Report:\n", report)

# Calculate ROC curve and AUC for the validation set
y_prob = best_model.predict_proba(x_valid_best)[: , 1] # Get probability
estimates for the positive class
fpr, tpr, _ = roc_curve(y_valid, y_prob)
roc_auc = auc(fpr, tpr)

# Plot the ROC curve
plt.figure()
plt.plot(fpr, tpr, color='darkorange', lw=2, label=f'ROC curve (AUC =
{roc_auc:.4f})')
plt.plot([0, 1], [0, 1], color='navy', lw=2, linestyle='--')
plt.xlim([0.0, 1.0])
plt.ylim([0.0, 1.05])
plt.xlabel('False Positive Rate')
plt.ylabel('True Positive Rate')
```

```
plt.title('Receiver Operating Characteristic')
plt.legend(loc="lower right")
plt.show()

# Print confusion matrix
conf_matrix = confusion_matrix(y_valid, y_pred)
disp = ConfusionMatrixDisplay(confusion_matrix=conf_matrix)
disp.plot()
plt.title("Confusion Matrix")
plt.show()

# Print ROC AUC
print(f"AUC (ROC): {roc_auc:.4f}")
```

#### Απόσπασμα κώδικα A.5: Μοντέλο SVM

```
import numpy as np
import pandas as pd
import itertools
from sklearn.preprocessing import StandardScaler
from imblearn.over_sampling import RandomOverSampler
from sklearn.model_selection import cross_val_score, train_test_split,
GridSearchCV
from sklearn.svm import SVC
from sklearn.metrics import classification_report, roc_curve, auc,
confusion_matrix, ConfusionMatrixDisplay
from sklearn.feature_selection import SelectKBest, f_classif
import matplotlib.pyplot as plt

# Load the dataset
df = pd.read_excel("/content/emg_feature_data.xlsx")

# Split the dataset into training, validation, and test sets
train, valid, test = np.split(df.sample(frac=1, random_state=42),
[int(0.6*len(df)), int(0.8*len(df))])

# Function to scale datasets
def scale_dataset(dataframe, oversample=False):
    # Separate features and target variable
    x = dataframe[dataframe.columns[:-1]].values
    y = dataframe[dataframe.columns[-1]].values

    # Scale features
    scaler = StandardScaler()
    x = scaler.fit_transform(x)

    # Oversample the minority class if specified
    if oversample:
        ros = RandomOverSampler(random_state=42)
        x, y = ros.fit_resample(x, y)

    return x, y

# Scale the datasets
x_train, y_train = scale_dataset(train, oversample=True)
x_valid, y_valid = scale_dataset(valid, oversample=False)
x_test, y_test = scale_dataset(test, oversample=False)

# Select top 5 features using ANOVA F-test
selector = SelectKBest(f_classif, k=5)
x_train_best = selector.fit_transform(x_train, y_train)
x_valid_best = selector.transform(x_valid)
x_test_best = selector.transform(x_test)
```

Ο ΡΟΛΟΣ ΤΗΣ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ ΣΤΗΝ ΠΡΟΒΛΕΨΗ ΝΕΥΡΟΛΟΓΙΚΩΝ ΑΠΟΤΕΛΕΣΜΑΤΩΝ ΑΠΟ  
ΔΕΔΟΜΕΝΑ ΕΝΔΟΕΓΧΕΙΡΗΤΙΚΗΣ ΝΕΥΡΟΠΑΡΑΚΟΛΟΥΘΗΣΗΣ

```
selected_features = selector.get_support(indices=True)
best_features = df.columns[selected_features]

# Define parameter grid for SVM
param_grid = {
    'C': [0.1, 1, 10],
    'kernel': ['linear', 'rbf'],
    'gamma': ['scale', 'auto']
}

# Perform grid search with cross-validation
svm = SVC(probability=True) # Enable probability=True for ROC-AUC
calculation
grid_search = GridSearchCV(svm, param_grid, cv=3, n_jobs=-1,
scoring='accuracy')
grid_search.fit(x_train_best, y_train)

# Get the best model
best_model = grid_search.best_estimator_
best_params = grid_search.best_params_
best_accuracy = grid_search.best_score_

print(f"Best Features: {best_features}, Best Params: {best_params},
Accuracy: {best_accuracy:.4f}")

# Validate the best model on the validation set
y_pred = best_model.predict(x_valid_best)

# Print classification report
report = classification_report(y_valid, y_pred)
print("Classification Report:\n", report)

# Calculate ROC curve and AUC for the validation set
y_prob = best_model.predict_proba(x_valid_best)[:, 1] # Get probability
estimates for the positive class
fpr, tpr, _ = roc_curve(y_valid, y_prob)
roc_auc = auc(fpr, tpr)

# Plot the ROC curve
plt.figure()
plt.plot(fpr, tpr, color='darkorange', lw=2, label=f'ROC curve (AUC =
{roc_auc:.4f})')
plt.plot([0, 1], [0, 1], color='navy', lw=2, linestyle='--')
plt.xlim([0.0, 1.0])
plt.ylim([0.0, 1.05])
plt.xlabel('False Positive Rate')
plt.ylabel('True Positive Rate')
plt.title('Receiver Operating Characteristic')
plt.legend(loc="lower right")
plt.show()

# Print confusion matrix
conf_matrix = confusion_matrix(y_valid, y_pred)
disp = ConfusionMatrixDisplay(confusion_matrix=conf_matrix)
disp.plot()
plt.title("Confusion Matrix")
plt.show()

# Print ROC AUC
print(f"AUC (ROC): {roc_auc:.4f}")
```

**Απόσπασμα κώδικα A.6:** Μοντέλο Neural Networks

Ο ΡΟΛΟΣ ΤΗΣ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ ΣΤΗΝ ΠΡΟΒΛΕΨΗ ΝΕΥΡΟΛΟΓΙΚΩΝ ΑΠΟΤΕΛΕΣΜΑΤΩΝ ΑΠΟ  
ΔΕΔΟΜΕΝΑ ΕΝΔΟΕΓΧΕΙΡΗΤΙΚΗΣ ΝΕΥΡΟΠΑΡΑΚΟΛΟΥΘΗΣΗΣ

```
import numpy as np
import pandas as pd
from sklearn.preprocessing import StandardScaler
from imblearn.over_sampling import RandomOverSampler
from sklearn.model_selection import train_test_split, GridSearchCV
from sklearn.neural_network import MLPClassifier
from sklearn.metrics import classification_report, roc_curve, auc,
confusion_matrix, ConfusionMatrixDisplay, accuracy_score,
precision_score, recall_score, f1_score
from sklearn.feature_selection import SelectKBest, f_classif
import matplotlib.pyplot as plt

# Load the dataset
df = pd.read_excel("/content/emg_feature_data.xlsx")

# Split the dataset into training, validation, and test sets
train, valid, test = np.split(df.sample(frac=1, random_state=42),
[0.6*len(df), 0.8*len(df)])

# Function to scale datasets
def scale_dataset(dataframe, oversample=False):
    # Separate features and target variable
    x = dataframe[dataframe.columns[:-1]].values
    y = dataframe[dataframe.columns[-1]].values

    # Scale features
    scaler = StandardScaler()
    x = scaler.fit_transform(x)

    # Oversample the minority class if specified
    if oversample:
        ros = RandomOverSampler(random_state=42)
        x, y = ros.fit_resample(x, y)

    return x, y

# Scale the datasets
x_train, y_train = scale_dataset(train, oversample=True)
x_valid, y_valid = scale_dataset(valid, oversample=False)
x_test, y_test = scale_dataset(test, oversample=False)

# Select top 3 features using ANOVA F-test
selector = SelectKBest(f_classif, k=3)
x_train_best = selector.fit_transform(x_train, y_train)
x_valid_best = selector.transform(x_valid)
x_test_best = selector.transform(x_test)
selected_features = selector.get_support(indices=True)
best_features = df.columns[selected_features]

# Define parameter grid for Neural Network
param_grid = {
    'hidden_layer_sizes': [(50,), (100,), (50, 50), (100, 100)],
    'activation': ['tanh', 'relu'],
    'solver': ['sgd', 'adam'],
    'alpha': [0.0001, 0.001, 0.01],
    'learning_rate': ['constant', 'adaptive'],
    'max_iter': [200, 300, 400]
}

# Perform grid search with cross-validation
nn = MLPClassifier(random_state=42)
grid_search = GridSearchCV(nn, param_grid, cv=5, n_jobs=-1,
scoring='accuracy')
```

Ο ΡΟΛΟΣ ΤΗΣ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ ΣΤΗΝ ΠΡΟΒΛΕΨΗ ΝΕΥΡΟΛΟΓΙΚΩΝ ΑΠΟΤΕΛΕΣΜΑΤΩΝ ΑΠΟ  
ΔΕΔΟΜΕΝΑ ΕΝΔΟΕΓΧΕΙΡΗΤΙΚΗΣ ΝΕΥΡΟΠΑΡΑΚΟΛΟΥΘΗΣΗΣ

```
grid_search.fit(x_train_best, y_train)

# Get the best model
best_model = grid_search.best_estimator_
best_params = grid_search.best_params_
best_accuracy = grid_search.best_score_

print(f"Best Features: {best_features}, Best Params: {best_params},
Accuracy: {best_accuracy:.4f}")

# Validate the best model on the validation set
y_pred_valid = best_model.predict(x_valid_best)

# Get training predictions for performance metrics
y_pred_train = best_model.predict(x_train_best)

# Print classification report for validation set
report_valid = classification_report(y_valid, y_pred_valid)
print("Validation Classification Report:\n", report_valid)

# Calculate and print accuracy, precision, recall, and F1 for the training
set
train_accuracy = accuracy_score(y_train, y_pred_train)
train_precision = precision_score(y_train, y_pred_train,
average='weighted')
train_recall = recall_score(y_train, y_pred_train, average='weighted')
train_f1 = f1_score(y_train, y_pred_train, average='weighted')

print(f"Train Accuracy: {train_accuracy:.4f}")
print(f"Train Precision: {train_precision:.4f}")
print(f"Train Recall: {train_recall:.4f}")
print(f"Train F1-Score: {train_f1:.4f}")

# Calculate ROC curve and AUC for the validation set
y_prob_valid = best_model.predict_proba(x_valid_best)[: , 1] # Get
probability estimates for the positive class
fpr_valid, tpr_valid, _ = roc_curve(y_valid, y_prob_valid)
roc_auc_valid = auc(fpr_valid, tpr_valid)

# Calculate ROC curve and AUC for the training set
y_prob_train = best_model.predict_proba(x_train_best)[: , 1] # Get
probability estimates for the positive class
fpr_train, tpr_train, _ = roc_curve(y_train, y_prob_train)
roc_auc_train = auc(fpr_train, tpr_train)

# Plot both ROC curves on the same graph
plt.figure()
plt.plot(fpr_train, tpr_train, color='blue', lw=2, label=f'Train ROC curve
(AUC = {roc_auc_train:.4f})')
plt.plot(fpr_valid, tpr_valid, color='darkorange', lw=2,
label=f'Validation ROC curve (AUC = {roc_auc_valid:.4f})')
plt.plot([0, 1], [0, 1], color='navy', lw=2, linestyle='--')
plt.xlim([0.0, 1.0])
plt.ylim([0.0, 1.05])
plt.xlabel('False Positive Rate')
plt.ylabel('True Positive Rate')
plt.title('ROC Curve: Train and Validation')
plt.legend(loc="lower right")
plt.show()

# Print confusion matrix for validation set
conf_matrix = confusion_matrix(y_valid, y_pred_valid)
disp = ConfusionMatrixDisplay(confusion_matrix=conf_matrix)
```

Ο ΡΟΛΟΣ ΤΗΣ ΜΗΧΑΝΙΚΗΣ ΜΑΘΗΣΗΣ ΣΤΗΝ ΠΡΟΒΛΕΨΗ ΝΕΥΡΟΛΟΓΙΚΩΝ ΑΠΟΤΕΛΕΣΜΑΤΩΝ ΑΠΟ  
ΔΕΔΟΜΕΝΑ ΕΝΔΟΕΓΧΕΙΡΗΤΙΚΗΣ ΝΕΥΡΟΠΑΡΑΚΟΛΟΥΘΗΣΗΣ

```
disp.plot()  
plt.title("Validation Confusion Matrix")  
plt.show()  
  
# Print ROC AUC  
print(f"Validation AUC (ROC): {roc_auc_valid:.4f}")  
print(f"Train AUC (ROC): {roc_auc_train:.4f}")
```