

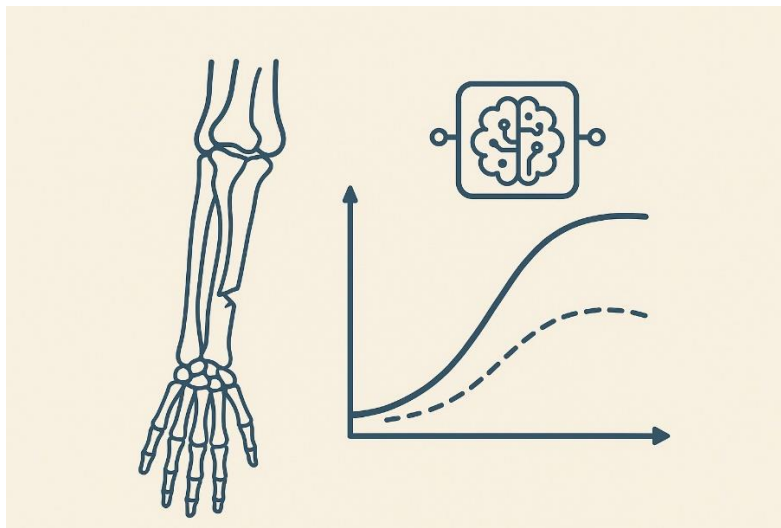


ΔΙΕΘΝΕΣ  
ΠΑΝΕΠΙΣΤΗΜΙΟ  
ΤΗΣ ΕΛΛΑΔΟΣ

ΣΧΟΛΗ ΜΗΧΑΝΙΚΩΝ  
ΤΜΗΜΑ ΜΗΧΑΝΙΚΩΝ ΠΛΗΡΟΦΟΡΙΚΗΣ  
ΚΑΙ ΗΛΕΚΤΡΟΝΙΚΩΝ ΣΥΣΤΗΜΑΤΩΝ

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

«Εκτίμηση Χρόνου Αποκατάστασης Ορθοπεδικών  
Κακώσεων με Χρήση Μηχανικής Μάθησης»



Της φοιτήτριας  
Τσιλοφύτη Παρασκευή  
Αρ. Μητρώου: 2020177

Επιβλέπων  
Αδαμίδης Παναγιώτης  
Καθηγητής

Σεπτέμβριος 2025

Τίτλος Δ.Ε. Εκτίμηση Χρόνου Αποκατάστασης Ορθοπεδικών Κακώσεων με Χρήση Μηχανικής  
Μάθησης

Κωδικός Δ.Ε. 25239

Όνοματεπώνυμο φοιτητή Τσιλοφύτη Παρασκευή

Όνοματεπώνυμο εισηγητή: Αδαμίδης Παναγιώτης

Ημερομηνία ανάληψης Δ.Ε.: 31-03-2025

Ημερομηνία περάτωσης Δ.Ε.: 12-09-2025

*Βεβαιώνω ότι είμαι ο συγγραφέας αυτής της εργασίας και ότι κάθε βοήθεια την οποία είχα για την προετοιμασία της είναι πλήρως αναγνωρισμένη και αναφέρεται στην εργασία. Επίσης, έχω καταγράψει τις όποιες πηγές από τις οποίες έκανα χρήση δεδομένων, ιδεών, εικόνων και κειμένου, είτε αυτές αναφέρονται ακριβώς είτε παραφρασμένες. Επιπλέον, βεβαιώνω ότι αυτή η εργασία προετοιμάστηκε από εμένα προσωπικά, ειδικά ως διπλωματική εργασία, στο Τμήμα Μηχανικών Πληροφορικής και Ηλεκτρονικών Συστημάτων του ΔΙ.ΠΑ.Ε.*

*Η παρούσα εργασία αποτελεί πνευματική ιδιοκτησία της φοιτήτριας Τσιλοφύτη Παρασκευής που την εκπόνησε. Στο πλαίσιο της πολιτικής ανοικτής πρόσβασης, ο συγγραφέας/δημιουργός εκχωρεί στο Διεθνές Πανεπιστήμιο της Ελλάδος άδεια χρήσης του δικαιώματος αναπαραγωγής, δανεισμού, παρουσίασης στο κοινό και ψηφιακής διάχυσης της εργασίας διεθνώς, σε ηλεκτρονική μορφή και σε οποιοδήποτε μέσο, για διδακτικούς και ερευνητικούς σκοπούς, άνευ ανταλλάγματος. Η ανοικτή πρόσβαση στο πλήρες κείμενο της εργασίας, δεν σημαίνει καθ' οιονδήποτε τρόπο παραχώρηση δικαιωμάτων διανοητικής ιδιοκτησίας του συγγραφέα/δημιουργού, ούτε επιτρέπει την αναπαραγωγή, αναδημοσίευση, αντιγραφή, πώληση, εμπορική χρήση, διανομή, έκδοση, μεταφόρτωση (downloading), ανάρτηση (uploading), μετάφραση, τροποποίηση με οποιοδήποτε τρόπο, τμηματικά ή περιληπτικά της εργασίας, χωρίς τη ρητή προηγούμενη έγγραφη συναίνεση του συγγραφέα/δημιουργού.*

Η έγκριση της διπλωματικής εργασίας από το Τμήμα Μηχανικών Πληροφορικής και Ηλεκτρονικών Συστημάτων του Διεθνούς Πανεπιστημίου της Ελλάδος, δεν υποδηλώνει απαραίτητως και αποδοχή των απόψεων του συγγραφέα, εκ μέρους του Τμήματος.

## Πρόλογος

Η ταχεία εξέλιξη της τεχνολογίας και ειδικότερα της τεχνητής νοημοσύνης ανοίγει νέους ορίζοντες στην σύγχρονη ιατρική. Στην παρούσα διπλωματική, εστιάζω στη διερεύνηση του ρόλου αυτών των καινοτόμων εργαλείων στην εκτίμηση του χρόνου αποκατάστασης μετά από ορθοπεδικές κακώσεις. Ένα πεδίο με μεγάλη κλινική και κοινωνική σημασία. Η δυνατότητα πρόβλεψης του χρόνου αποκατάστασης αποτελεί κρίσιμο παράγοντα για την βελτίωση της ποιότητας ζωής των ασθενών και την ορθολογική οργάνωση της θεραπείας τους.

Μέσα από τη διαδικασία εκπόνησης της εργασίας, είχα την ευκαιρία να εμβαθύνω στις αρχές της μηχανικής μάθησης, να εξοικειωθώ με σύγχρονες τεχνικές ανάλυσης δεδομένων και να αναπτύξω πρακτικές δεξιότητες στην υλοποίηση διαδραστικών εφαρμογών. Το όφελος που αποκόμισα είναι πολύπλευρο, καθώς απέκτησα τόσο θεωρητική γνώση όσο και εμπειρία στην εφαρμογή καινοτόμων τεχνολογιών στην ιατρική πληροφορική, γεγονός που ενισχύει την επιστημονική και επαγγελματική μου εξέλιξη.

## Περίληψη

Η παρούσα διπλωματική εργασία εστιάζει στην εκτίμηση του χρόνου αποκατάστασης ορθοπεδικών κακώσεων με τη χρήση σύγχρονων μεθόδων μηχανικής μάθησης. Στόχος της μελέτης είναι η ανάπτυξη και αξιολόγηση προγνωστικών μοντέλων που επιτρέπουν την ακριβέστερη πρόβλεψη του χρόνου που απαιτείται για την πλήρη λειτουργική αποκατάσταση ασθενών μετά από ορθοπεδικά τραύματα, λαμβάνοντας υπόψη δημογραφικά, κλινικά και λειτουργικά χαρακτηριστικά.

Δεδομένης της απουσίας δημοσίως διαθέσιμων συνόλων δεδομένων με επαρκή πληροφορία για την πρόγνωση χρόνου αποκατάστασης σε τέτοιου είδους κακώσεις, δημιουργήθηκε συνθετικό σύνολο δεδομένων που αναπαριστά ρεαλιστικά προφίλ ασθενών και χαρακτηριστικά κακώσεων. Αυτό επέτρεψε την εκπαίδευση και δοκιμή αλγορίθμων χωρίς να τίθεται σε κίνδυνο η ιδιωτικότητα των πραγματικών ασθενών.

Τα αποτελέσματα της ανάλυσης ανέδειξαν ως σημαντικότερους προγνωστικούς παράγοντες την ηλικία, τον δείκτη παράλληλων παθήσεων, την παρουσία οστεοπόρωσης, τη σταθερότητα του κατάγματος και τη διάρκεια ακινητοποίησης. Τα μοντέλα μηχανικής μάθησης που αναπτύχθηκαν παρουσίασαν ικανοποιητική ακρίβεια πρόβλεψης, επιβεβαιώνοντας τη δυνατότητα αξιοποίησής τους στην υποστήριξη της κλινικής απόφασης.

Επιπλέον, αναπτύχθηκε διαδραστική εφαρμογή με χρήση της πλατφόρμας Streamlit, η οποία επιτρέπει την εισαγωγή εξατομικευμένων δεδομένων ασθενούς και την άμεση πρόβλεψη του χρόνου αποκατάστασης, συνοδευόμενη από γραφικές απεικονίσεις και δείκτες κινδύνου. Η εφαρμογή αυτή στοχεύει στη γεφύρωση του χάσματος μεταξύ ερευνητικής προσέγγισης και κλινικής πράξης, διευκολύνοντας τον σχεδιασμό εξατομικευμένων θεραπευτικών πλάνων, ενώ ενισχύει και την επικοινωνία με τον ασθενή, προσφέροντας σαφή και κατανοητή απεικόνιση των προβλέψεων.

Συνολικά, η εργασία αναδεικνύει τη δυναμική της τεχνητής νοημοσύνης και της μηχανικής μάθησης στην ορθοπεδική αποκατάσταση, θέτοντας τις βάσεις για μελλοντική εφαρμογή και επικύρωση των προτεινόμενων εργαλείων σε πραγματικά κλινικά δεδομένα.

# Estimation of Recovery Time for Orthopedic Injuries Using Machine Learning

Paraskevi Tsilofiti

## Abstract

This thesis investigates the estimation of recovery time for orthopedic injuries through the application of engineering methodologies and computational modeling using state-of-the-art machine learning methods. The aim of the study is to develop and evaluate predictive models that can accurately estimate the time required for patients to achieve full functional recovery after orthopedic trauma, based on demographic, clinical, and functional characteristics.

Due to the lack of publicly available datasets that include sufficient detail on orthopedic recovery timelines, a synthetic dataset was created to realistically simulate patient profiles and injury characteristics. This approach enabled the training and evaluation of algorithms without compromising patient privacy.

The results identified age, comorbidity index, presence of osteoporosis, fracture stability, and immobilization duration as key predictors of recovery time. The developed machine learning models, particularly those based on ensemble methods, achieved satisfactory predictive accuracy, confirming their potential to support clinical decision support.

Furthermore, an interactive application was developed using the Streamlit platform, allowing users to input individualized patient data and receive real-time recovery predictions, accompanied by visual representations and risk indicators. This tool aims to bridge the gap between research and clinical practice, facilitating the design of personalized rehabilitation plans and enhancing communication with patients through accessible and informative feedback.

Overall, this thesis underscores the potential of artificial intelligence and machine learning in orthopedic rehabilitation, offering practical solutions for more precise and individualized patient care and setting the foundation for future deployment and validation of such tools in real-world clinical settings.

# Περιεχόμενα

Πρόλογος.....	iii
Περίληψη.....	iv
Abstract .....	v
Περιεχόμενα .....	vi
Κατάλογος Σχημάτων .....	x
Κατάλογος Πινάκων.....	x
Συντομογραφίες.....	xi
Κεφάλαιο 1ο: Εισαγωγή .....	1
1.1 Στόχος και Σκοπός της Εργασίας.....	1
1.2 Σημασία Πρόβλεψης Χρόνου Αποκατάστασης .....	1
1.3 Δομή της Εργασίας.....	2
1.4 Επίλογος.....	2
Κεφάλαιο 2ο: Θεωρητικό Υπόβαθρο.....	3
2.1 Εισαγωγή.....	3
2.2 Μηχανική Μάθηση και Επιβλεπόμενη Μάθηση.....	3
2.3 Μέθοδοι Regression .....	5
2.3.1 Βασικές μέθοδοι παλινδρόμησης .....	5
2.3.2 Εφαρμογές παλινδρόμησης στην ιατρική.....	6
2.4 Αλγόριθμοι που Χρησιμοποιήθηκαν.....	7
2.4.1 Γραμμική Παλινδρόμηση και Ridge Regression.....	7
2.4.2 XGBoost.....	8
2.4.3 Random Forest.....	9
2.4.4 Τεχνητά Νευρωνικά Δίκτυα (Artificial Neural Networks).....	9
2.5 Ερμηνευσιμότητα Μοντέλων .....	10
2.5.1 Σημασία Χαρακτηριστικών .....	10
2.5.2 Τιμές SHAP .....	11
2.5.3 Σύγκριση Feature Importance και SHAP .....	12
2.6 Επίλογος.....	12
Κεφάλαιο 3ο: Ανασκόπηση Βιβλιογραφίας.....	13
3.1 Πρόβλεψη Αποκατάστασης .....	13
3.1.1 Επισκόπηση Εργασιών σε Κατάγματα .....	14
3.1.2 Επισκόπηση Εργασιών σε Άλλες Παθήσεις.....	15

3.1.3	Σύνοψη και Κενά στη Βιβλιογραφία.....	16
3.2	Βάσεις Δεδομένων και Μελέτες σε Κατάγματα.....	16
3.2.1	Παρουσίαση Κύριων Βάσεων Δεδομένων .....	16
3.2.2	Ανάλυση Ενδεικτικών Μελετών .....	17
3.2.3	Συζήτηση – Προκλήσεις και Προοπτικές.....	18
3.3	Έλλειψη Διαθέσιμων Δεδομένων και Συνθετικό Dataset .....	18
3.3.1	Προβλήματα Έλλειψης Διαθέσιμων Δεδομένων .....	18
3.3.2	Κίνητρο για Δημιουργία Συνθετικών Δεδομένων .....	19
3.3.3	Περιορισμοί και Προκλήσεις των Συνθετικών Δεδομένων.....	20
3.3.4	Συμπεράσματα.....	20
3.4	Σχετικές Μελέτες σε Άλλες Παθήσεις .....	21
3.4.1	Μελέτες σε Αποκατάσταση Πρόσθιου Χιαστού Συνδέσμου .....	21
3.4.2	Μελέτες σε Αποκατάσταση Ισχίου.....	21
3.4.3	Παραδείγματα από Άλλες Ορθοπεδικές Παθήσεις.....	22
3.4.4	Παραδείγματα από Νευρολογικές/Άλλες Παθήσεις.....	23
3.4.5	Συμπεράσματα.....	23
3.5	Επίλογος.....	24
Κεφάλαιο 4ο:	Δημιουργία Συνθετικού Dataset .....	25
4.1	Επιλογή Παθολογίας .....	25
4.2	Επιλογή και Περιγραφή Μεταβλητών.....	26
4.2.1	Δημογραφικές μεταβλητές .....	26
4.2.2	Κλινικές μεταβλητές.....	27
4.2.3	Λειτουργικές μεταβλητές .....	27
4.2.4	Σύνθετες μεταβλητές.....	28
4.3	Διαδικασία Δημιουργίας Συνθετικών Δεδομένων.....	28
4.4	Στατιστική Ανάλυση και Έλεγχος Συνέπειας.....	29
4.5	Ηθικά Ζητήματα Συνθετικών Δεδομένων.....	30
4.6	Επίλογος.....	30
Κεφάλαιο 5ο:	Ανάπτυξη και Εκπαίδευση Μοντέλου .....	32
5.1	Προεπεξεργασία Δεδομένων .....	32
5.1.1	Διαχωρισμός Χαρακτηριστικών και Στόχου .....	32
5.1.2	Καθαρισμός και μετασχηματισμός δεδομένων .....	33
5.1.3	Διαχωρισμός σε train/test set.....	33
5.2	Εκπαίδευση Μοντέλου XGBoost.....	34
5.2.1	Παρουσίαση του XGBoost.....	34

5.2.2	Εκπαίδευση και επιλογή υπερπαραμέτρων .....	34
5.2.3	Cross-validation.....	35
5.3	Αξιολόγηση Απόδοσης.....	35
5.3.1	Μετρικές αξιολόγησης .....	35
5.3.2	Παρουσίαση αποτελεσμάτων .....	36
5.4	Σύγκριση με Άλλα Μοντέλα .....	38
5.5	Επίλογος.....	40
Κεφάλαιο 6ο:	Ερμηνεία Μοντέλου και Ανάλυση.....	41
6.1	Feature Importance.....	41
6.1.1	Θεωρητικό Υπόβαθρο Feature Importance .....	41
6.1.2	Υπολογισμός feature importance στο XGBoost.....	42
6.1.3	Παρουσίαση και ανάλυση αποτελεσμάτων .....	42
6.2	SHAP Values και SHAP Interaction Plots .....	43
6.2.1	Θεωρητικό υπόβαθρο των SHAP values.....	43
6.2.2	SHAP summary plot.....	43
6.2.3	SHAP dependence plots .....	44
6.2.4	SHAP interaction plots .....	44
6.2.5	Συνολικός σχολιασμός.....	45
6.3	Ανάλυση Σφαλμάτων και Outliers .....	45
6.3.1	Εντοπισμός και ποσοτική ανάλυση σφαλμάτων .....	45
6.3.2	Ανάλυση outliers .....	46
6.3.3	Ερμηνεία και επιπτώσεις σφαλμάτων .....	46
6.4	Ανάλυση Υποομάδων Χρηστών (Subgroup Analysis) .....	47
6.4.1	Θεωρητικό υπόβαθρο και σημασία της ανάλυσης υποομάδων.....	47
6.4.2	Μεθοδολογία ανάλυσης υποομάδων .....	47
6.4.3	Παρουσίαση και σχολιασμός αποτελεσμάτων .....	48
6.4.4	Στρατηγικές βελτίωσης και μελλοντικές προεκτάσεις .....	48
6.5	What-if Analysis.....	48
6.5.1	Θεωρητικό υπόβαθρο του what-if analysis .....	49
6.5.2	Μεθοδολογία εφαρμογής what-if analysis .....	49
6.5.3	Παραδείγματα εφαρμογής .....	50
6.5.4	Ερμηνεία και κλινική σημασία.....	50
6.6	Επίλογος.....	50
Κεφάλαιο 7ο:	Εφαρμογή Streamlit.....	52
7.1	Λειτουργικότητα και Περιγραφή Εφαρμογής .....	52

7.1.1	Περιγραφή της διεπαφής χρήστη (UI).....	52
7.1.2	Παρουσίαση αποτελεσμάτων .....	53
7.2	Παρουσίαση Κώδικα και Αρχιτεκτονικής.....	55
7.2.1	Συνοπτική περιγραφή της αρχιτεκτονικής της εφαρμογής.....	55
7.2.2	Ανάλυση βασικών λειτουργικών ενοτήτων του κώδικα .....	56
7.2.3	Παράδειγμα αποσπάσματος κώδικα.....	56
7.3	Γραφική Παρουσίαση Αποτελεσμάτων .....	58
7.3.1	Παρουσίαση των βασικών διαγραμμάτων της εφαρμογής.....	58
7.3.2	Ερμηνεία και χρησιμότητα των γραφικών .....	59
7.3.3	Σχόλια για τη βελτίωση της οπτικοποίησης .....	59
7.4	Προτάσεις Βελτίωσης και Μελλοντική Χρήση .....	59
7.5	Επίλογος.....	60
Κεφάλαιο 8ο:	Συμπεράσματα και Μελλοντική Εργασία.....	61
8.1	Συνοπτικά Ευρήματα.....	61
8.2	Πλεονεκτήματα και Περιορισμοί.....	61
8.3	Προτάσεις για Εφαρμογή σε Πραγματικά Δεδομένα.....	62
8.4	Δυνατότητες Επέκτασης της Έρευνας.....	62
8.5	Επίλογος.....	63
	<b>ΒΙΒΛΙΟΓΡΑΦΙΑ.....</b>	<b>64</b>

## Κατάλογος Σχημάτων

Σχήμα 2.1: ER Diagram Συνθετικού Dataset .....	6
Σχήμα 2.2: SHAP dependence plot .....	11
Σχήμα 3.1: Pipeline Μηχανικής Μάθησης.....	14
Σχήμα 4.1: Κατανομή Ηλικίας Ασθενών .....	26
Σχήμα 4.2: Στιγμιότυπο Κώδικα Δημιουργίας Δεδομένων.....	28
Σχήμα 5.4 : Scatter Plot Πραγματικών vs Προβλεπόμενων.....	37
Σχήμα 5.5 : Bar Chart Feature Importance.....	37
Σχήμα 5.6: SHAP Summary Plot .....	38
Σχήμα 5.7: Σφάλμα Ανά Τύπο Κατάγματος .....	38
Σχήμα 5.8: Σύγκριση RMSE Μεταξύ Μοντέλων.....	40
Σχήμα 7.1: Στιγμιότυπο διεπαφής χρήστη (Streamlit) της εφαρμογής εκτίμησης χρόνου αποκατάστασης. ....	53
Σχήμα 7.2: Σελίδα αποτελεσμάτων (Streamlit). Πρόσθετες λειτουργίες διεπαφής .....	54
Σχήμα 7.3 Σχήμα 7.3 : Κατανομή χρόνου αποκατάστασης (εβδομάδες) στο δείγμα. ....	56

## Κατάλογος Πινάκων

Πίνακας 2.1: Σύγκριση Μεθοδολογιών.....	5
Πίνακας 5.1: Σύγκριση Απόδοσης Μοντέλων ως προς MAE, RMSE και R <sup>2</sup> .....	39

## Συντομογραφίες

ACL(Anterior Cruciate Ligament)	Πρόσθιος Χιαστός Σύνδεσμος
DEXA(Dual-energy X-ray Absorptiometry)	Απορροφησιομετρία διπλής ενέργειας ακτίνων Χ.
CCI(Charlson Comorbidity Index)	Δείκτης Συννοσηρότητας Charlson
MAE(Mean Absolute Error)	Μέσο Απόλυτο Σφάλμα
RMSE(Root Mean Squared Error)	Ριζική Μέση Τετραγωνική Απόκλιση
XGBoost	eXtreme Gradient Boosting
ANN (Artificial Neural Network)	Τεχνητό Νευρωνικό Δίκτυο
SHAP	SHapley Additive exPlanations
SVM	Support Vector Machine
GDPR	General Data Protection Regulation
HIPAA	Health Insurance Portability and Accountability Act
GANs	Generative Adversarial Networks
AI	Artificial Intelligence
MLP	Multi-Layer Perceptron
FAQ	Frequently Asked Questions
LIME	Local Interpretable Model-agnostic Explanations
EHRs	Electronic Health Records

## Κεφάλαιο 1ο: Εισαγωγή

### 1.1 Στόχος και Σκοπός της Εργασίας

Η παρούσα εργασία επικεντρώνεται στην ανάπτυξη και αξιολόγηση καινοτόμων μεθοδολογιών για την εκτίμηση του χρόνου αποκατάστασης μετά από ορθοπεδικές κακώσεις, με ιδιαίτερη έμφαση στα κατάγματα της περιφερικής κερκίδας, αξιοποιώντας σύγχρονες τεχνικές μηχανικής μάθησης και υπολογιστικής ανάλυσης [3]. Σε αρχικό στάδιο πραγματοποιήθηκε συστηματική αναζήτηση πραγματικών κλινικών δεδομένων. Διαπιστώθηκε ότι δεν υπήρχαν δημόσια διαθέσιμα σύνολα με επαρκείς μεταβλητές και σαφή καταληκτικά σημεία (π.χ. χρόνος πλήρους λειτουργικής αποκατάστασης), ενώ η πρόσβαση σε μη δημόσιες βάσεις περιοριζόταν από ζητήματα ιδιωτικότητας και ετερογένειας πρωτοκόλλων. Ως εκ τούτου, επιλέχθηκε τεκμηριωμένα η δημιουργία συνθετικού συνόλου δεδομένων ως λύση ανάγκης, με στόχο την ρεαλιστική αναπαράσταση προφίλ ασθενών και χαρακτηριστικών κακώσεων, βάσει της διεθνούς βιβλιογραφίας [3][4].

Βασικός στόχος είναι η ανάπτυξη και αξιολόγηση προγνωστικών μοντέλων που ενισχύουν την ακρίβεια και την αξιοπιστία της πρόβλεψης του χρόνου αποκατάστασης, λαμβάνοντας υπόψη δημογραφικά, κλινικά και λειτουργικά χαρακτηριστικά. Σκοπός είναι να παρουσιαστεί μια ολοκληρωμένη προσέγγιση που συνδυάζει παραδοσιακές στατιστικές μεθόδους και σύγχρονες τεχνικές μηχανικής μάθησης, με εφαρμογή στο συνθετικό σύνολο δεδομένων και, όπου ήταν εφικτό, με αντιπαραβολή σε δείκτες και εύρη που αναφέρονται στη βιβλιογραφία. Αναδεικνύονται πλεονεκτήματα και περιορισμοί κάθε προσέγγισης και διατυπώνονται προτάσεις για μελλοντική εξωτερική επικύρωση σε πραγματικά κλινικά δεδομένα.

Η εργασία αποσκοπεί στη συμβολή τόσο στη θεωρητική κατανόηση όσο και στην πρακτική εφαρμογή της πρόβλεψης χρόνου αποκατάστασης, προσφέροντας χρήσιμα συμπεράσματα για την ακαδημαϊκή κοινότητα και τους επαγγελματίες υγείας.

### 1.2 Σημασία Πρόβλεψης Χρόνου Αποκατάστασης

Η πρόβλεψη του χρόνου αποκατάστασης μετά από κάταγμα της περιφερικής κερκίδας αποτελεί ένα από τα πλέον κρίσιμα ζητήματα στην ορθοπεδική και τη φυσικοθεραπευτική πρακτική, καθώς επηρεάζει άμεσα τον σχεδιασμό της θεραπείας, την ενημέρωση του ασθενούς και τη διαχείριση των προσδοκιών του [3]. Η ακριβής εκτίμηση του χρόνου που απαιτείται για την πλήρη λειτουργική αποκατάσταση επιτρέπει στους επαγγελματίες υγείας να προσαρμόζουν το θεραπευτικό πλάνο, να βελτιώνουν την κατανομή των πόρων και να ενισχύουν τη συμμόρφωση του ασθενούς με τις οδηγίες αποκατάστασης [4].

Η σημασία της πρόβλεψης αυτής αναδεικνύεται ακόμη περισσότερο στο πλαίσιο της εξατομικευμένης ιατρικής, όπου η λήψη αποφάσεων βασίζεται σε πολυπαραγοντικά μοντέλα που λαμβάνουν υπόψη δημογραφικά, κλινικά και λειτουργικά χαρακτηριστικά του ασθενούς. Η χρήση σύγχρονων τεχνικών μηχανικής μάθησης και η αξιοποίηση συνθετικών ή πραγματικών δεδομένων επιτρέπουν την ανάπτυξη εργαλείων που έχουν τη δυνατότητα να προσφέρουν ακριβέστερες και πιο αξιόπιστες προβλέψεις σε σχέση με τις παραδοσιακές μεθόδους [3].

Επιπλέον, η δυνατότητα πρόβλεψης του χρόνου αποκατάστασης συμβάλλει στη βελτίωση της επικοινωνίας μεταξύ ιατρού και ασθενούς, ενισχύει την ψυχολογική προετοιμασία του και διευκολύνει τον προγραμματισμό της επιστροφής του στις καθημερινές και επαγγελματικές του δραστηριότητες. Η

διεθνής βιβλιογραφία επιβεβαιώνει ότι η ενσωμάτωση προγνωστικών μοντέλων στην κλινική πράξη οδηγεί σε βελτιωμένα θεραπευτικά αποτελέσματα και αυξημένη ικανοποίηση των ασθενών [3][4].

### 1.3 Δομή της Εργασίας

Η παρούσα εργασία είναι δομημένη με τρόπο που διασφαλίζει τη συστηματική και ολοκληρωμένη προσέγγιση του ερευνητικού ερωτήματος, ακολουθώντας τις αρχές της επιστημονικής μεθοδολογίας και τις βέλτιστες πρακτικές της διεθνούς βιβλιογραφίας [4]. Αρχικά, παρουσιάζεται το θεωρητικό υπόβαθρο και η σχετική βιβλιογραφία που αφορά την πρόβλεψη του χρόνου αποκατάστασης, τη σημασία των συνθετικών δεδομένων και τη χρήση τεχνικών μηχανικής μάθησης στην ιατρική πληροφορική [3].

Στη συνέχεια, αναλύονται τα μεθοδολογικά βήματα που ακολουθήθηκαν για τη δημιουργία του συνθετικού συνόλου δεδομένων, την επιλογή και εκπαίδευση των μοντέλων, καθώς και την αξιολόγηση της απόδοσής τους. Ιδιαίτερη έμφαση δίνεται στην ανάπτυξη της διαδραστικής εφαρμογής «Streamlit», η οποία αποτελεί το πρακτικό αποτέλεσμα της εργασίας και αποσκοπεί στη γεφύρωση του χάσματος μεταξύ έρευνας και κλινικής πράξης.

Τέλος, η εργασία ολοκληρώνεται με την παρουσίαση των βασικών ευρημάτων, τη συζήτηση των πλεονεκτημάτων και των περιορισμών της προσέγγισης, καθώς και με προτάσεις για μελλοντική έρευνα και εφαρμογή σε πραγματικά κλινικά δεδομένα. Η δομή αυτή επιτρέπει στον αναγνώστη να κατανοήσει τόσο το θεωρητικό πλαίσιο όσο και την πρακτική υλοποίηση και αξιολόγηση του προτεινόμενου συστήματος.

### 1.4 Επίλογος

Συνοψίζοντας, το πρώτο κεφάλαιο θέτει τις βάσεις για την κατανόηση της σημασίας της πρόβλεψης του χρόνου αποκατάστασης και αναδεικνύει τη συμβολή της παρούσας εργασίας στην ανάπτυξη καινοτόμων μεθοδολογιών στον τομέα της ιατρικής πληροφορικής. Μέσα από τη συστηματική παρουσίαση του στόχου, της σημασίας και της δομής της εργασίας, καθίσταται σαφές ότι η αξιοποίηση συνθετικών δεδομένων και σύγχρονων τεχνικών μηχανικής μάθησης μπορεί να προσφέρει αξιόπιστα και πρακτικά εργαλεία υποστήριξης της ιατρικής απόφασης [3].

Η προσέγγιση που ακολουθείται στην εργασία αυτή ευθυγραμμίζεται με τις διεθνείς τάσεις για διαφάνεια, επαναληψιμότητα και αξιοποίηση της τεχνολογίας στην ιατρική έρευνα [4]. Η εισαγωγή αυτή προετοιμάζει τον αναγνώστη για την εις βάθος ανάλυση που ακολουθεί στα επόμενα κεφάλαια, όπου παρουσιάζονται τόσο το θεωρητικό πλαίσιο όσο και η πρακτική υλοποίηση και η αξιολόγηση του προτεινόμενου συστήματος πρόβλεψης.

## Κεφάλαιο 2ο: Θεωρητικό Υπόβαθρο

### 2.1 Εισαγωγή

Η μηχανική μάθηση (Machine Learning, ML) και η αναγνώριση προτύπων (Pattern Recognition) αποτελούν δύο άμεσα συνδεδεμένους επιστημονικούς τομείς οι οποίοι έχουν γνωρίσει ραγδαία ανάπτυξη τις τελευταίες δεκαετίες, με εφαρμογές που εκτείνονται τόσο τεχνολογικά πεδία όσο και τον τομέα της ιατρικής και της βιολογίας [2]. Αν και η αναγνώριση προτύπων έχει τις ρίζες της στη μηχανική και η μηχανική μάθηση στην επιστήμη των υπολογιστών, σήμερα οι δύο αυτοί κλάδοι θεωρούνται διαφορετικές όψεις του ίδιου επιστημονικού πεδίου.

Η εφαρμογή της μηχανικής μάθησης καθίσταται αναγκαία ιδίως σε προβλήματα όπου οι παραδοσιακές μεθοδολογίες, που στηρίζονται σε κανόνες ή χειροκίνητη ανάλυση, συχνά αποδεικνύονται ανεπαρκείς ή παρουσιάζουν μεγάλη πολυπλοκότητα. Ενδεικτικά παραδείγματα αποτελούν η αναγνώριση χειρόγραφων ψηφίων, το φιλτράρισμα ανεπιθύμητης αλληλογραφίας (spam), η αναγνώριση φωνής και η ανάλυση ιατρικών δεδομένων[2][3]. Σε τέτοιες περιπτώσεις, η μηχανική μάθηση επιτρέπει την αυτόματη εξαγωγή κανόνων και προτύπων από μεγάλα σύνολα δεδομένων, οδηγώντας σε αποδοτικότερες και περισσότερο προσαρμοστικές λύσεις.

Η μηχανική μάθηση διακρίνεται σε διάφορες κατηγορίες, με κυριότερες τη επιβλεπόμενη μάθηση (supervised learning), την μη επιβλεπόμενη μάθηση (unsupervised learning) και την ενισχυτική μάθηση (reinforcement learning). Στην επιβλεπόμενη μάθηση, ο αλγόριθμος εκπαιδεύεται με δεδομένα εισόδου και γνωστές τιμές εξόδου, επιδιώκοντας την πρόβλεψη της εξόδου για νέα, άγνωστα δεδομένα. Η μη επιβλεπόμενη μάθηση στοχεύει στην ανίχνευση δομών ή προτύπων σε δεδομένα χωρίς προκαθορισμένες ετικέτες, ενώ η ενισχυτική μάθηση βασίζεται στην αλληλεπίδραση με το περιβάλλον, με στόχο τη βελτιστοποίηση της συνολικής απόδοσης [2].

Η πρακτική σημασία της μηχανικής μάθησης είναι εμφανής σε πλήθος εφαρμογών της καθημερινότητας, όπως τα συστήματα σύστασης, η αυτόματη μετάφραση, η ανάλυση ιατρικών εικόνων και η πρόβλεψη κλινικών εκβάσεων. Ιδιαίτερα στον τομέα της υγείας, η μηχανική μάθηση προσφέρει νέες δυνατότητες για την ανάλυση πολύπλοκων και ετερογενών δεδομένων, συμβάλλοντας στη βελτίωση της διάγνωσης, της πρόγνωσης και της εξατομικευμένης θεραπείας.

Συνοψίζοντας, η μηχανική μάθηση συνιστά μια δυναμική και διαρκώς εξελισσόμενη τεχνολογία, η οποία διαμορφώνει το μέλλον της επιστήμης των δεδομένων και της τεχνολογίας, με σημαντικές εφαρμογές τόσο στον τομέα της Ιατρικής όσο και στην υγειονομική περίθαλψη.

### 2.2 Μηχανική Μάθηση και Επιβλεπόμενη Μάθηση

Η Μηχανική Μάθηση (Machine Learning, ML) αποτελεί έναν από τους σημαντικότερους και ταχύτερα εξελισσόμενους κλάδους της τεχνητής νοημοσύνης, με στόχο την ανάπτυξη αλγορίθμων που επιτρέπουν στους υπολογιστές να μαθαίνουν από δεδομένα και να βελτιώνουν την απόδοσή τους σε συγκεκριμένες εργασίες, χωρίς να έχουν προγραμματιστεί ρητά για αυτές[2] [3][5]. Η βασική αρχή της μηχανικής μάθησης έγκειται στη δυνατότητα ενός συστήματος να εξελίσσει τη συμπεριφορά του αξιοποιώντας την εμπειρία που αποκτά μέσω της ανάλυσης και επεξεργασίας δεδομένων. Όπως διατυπώνει και ο Tom Mitchell, «ένα πρόγραμμα υπολογιστή λέγεται ότι μαθαίνει από την εμπειρία E σε σχέση με κάποια εργασία T και κάποιο μέτρο απόδοσης P, αν η απόδοσή του στην εργασία T, όπως μετράται από το P, βελτιώνεται με την εμπειρία E» [6]. Το χαρακτηριστικό αυτό διαφοροποιεί τη

μηχανική μάθηση από τις παραδοσιακές μεθόδους προγραμματισμού, στις οποίες οι κανόνες και οι διαδικασίες καθορίζονται εξ αρχής από τον προγραμματιστή.

Η μηχανική μάθηση περιλαμβάνει διάφορες προσεγγίσεις, όπως αναφέρθηκε προηγουμένως, με κυριότερη την επιβλεπόμενη μάθηση (supervised learning), η οποία αποτελεί θεμέλιο για πολλές εφαρμογές στην επιστήμη και την τεχνολογία. Στην επιβλεπόμενη μάθηση, το σύστημα εκπαιδεύεται με τη χρήση ενός συνόλου δεδομένων όπου κάθε παράδειγμα συνοδεύεται από την αντίστοιχη επιθυμητή έξοδο (ετικέτα). Ο στόχος είναι η εκμάθηση μιας συνάρτησης που μπορεί να προβλέπει με ακρίβεια την έξοδο για νέα, άγνωστα δεδομένα [2][6]. Η προσέγγιση αυτή αντικατοπτρίζει τον τρόπο με τον οποίο οι άνθρωποι 'μαθαίνουν', βασιζόμενοι στην εμπειρία και στη συνεχή ανατροφοδότηση.

Η επιβλεπόμενη μάθηση διακρίνεται σε δύο βασικές κατηγορίες προβλημάτων: την ταξινόμηση (classification) και την παλινδρόμηση (regression). Στην ταξινόμηση, η έξοδος ανήκει σε διακριτές κατηγορίες, όπως για παράδειγμα η διάγνωση μιας ασθένειας ως «θετική» ή «αρνητική». Στην παλινδρόμηση, η έξοδος είναι μια συνεχής μεταβλητή, όπως η πρόβλεψη του χρόνου αποκατάστασης ενός ασθενούς ή της συγκέντρωσης μιας ουσίας στο αίμα [5]. Η επιλογή μεταξύ ταξινόμησης και παλινδρόμησης εξαρτάται από τη φύση του προβλήματος και τον τύπο των δεδομένων που διαθέτουμε.

Η διαδικασία εκπαίδευσης ενός αλγορίθμου επιβλεπόμενης μάθησης περιλαμβάνει τη χρήση ενός συνόλου εκπαίδευσης (training set), το οποίο αποτελείται από ζεύγη εισόδου-εξόδου. Ο αλγόριθμος προσαρμόζει τις παραμέτρους του ώστε να ελαχιστοποιεί το σφάλμα μεταξύ των προβλέψεών του και των πραγματικών τιμών. Στη συνέχεια, η απόδοση του μοντέλου αξιολογείται σε ένα ανεξάρτητο σύνολο δοκιμής (test set), προκειμένου να εκτιμηθεί η ικανότητά του να γενικεύει σε νέα δεδομένα. Η γενίκευση (generalization) αποτελεί σημαντικό παράγοντα ενός επιτυχημένου μοντέλου, καθώς διασφαλίζει ότι το μοντέλο δεν περιορίζεται μόνο στα δεδομένα με τα οποία εκπαιδεύτηκε, αλλά μπορεί να αποδώσει ικανοποιητικά και σε άγνωστα παραδείγματα [2] [5].

Η επιβλεπόμενη μάθηση βρίσκει εφαρμογή σε πλήθος επιστημονικών και τεχνολογικών πεδίων. Αναλυτικότερα στον τομέα της υγείας, χρησιμοποιείται για την ανάλυση ιατρικών εικόνων, την πρόβλεψη κλινικών εκβάσεων, την εξατομίκευση θεραπευτικών παρεμβάσεων και την υποστήριξη της λήψης ιατρικών αποφάσεων [3][7]. Για παράδειγμα, αλγόριθμοι επιβλεπόμενης μάθησης έχουν χρησιμοποιηθεί για την αυτόματη ανίχνευση ανωμαλιών σε ακτινογραφίες, την πρόβλεψη της πιθανότητας εμφάνισης επιπλοκών μετά από χειρουργικές επεμβάσεις, καθώς και για την εκτίμηση του χρόνου αποκατάστασης ασθενών με ορθοπεδικές κακώσεις. Επιπλέον, η επιβλεπόμενη μάθηση αξιοποιείται στην ανάλυση γονιδιακών δεδομένων, στην πρόβλεψη της ανταπόκρισης σε φαρμακευτικές αγωγές και στη διαχείριση ηλεκτρονικών ιατρικών φακέλων.

Εκτός από τον τομέα της Υγείας, η επιβλεπόμενη μάθηση έχει σημαντικές εφαρμογές στην αναγνώριση φωνής και εικόνας, στα συστήματα σύστασης, στη χρηματοοικονομική ανάλυση, στην ανίχνευση απάτης και στην αυτόνομη οδήγηση. Η ευρεία χρήση της οφείλεται στην ικανότητά της να αξιοποιεί μεγάλα και ετερογενή σύνολα δεδομένων, προσφέροντας αξιόπιστες και χρήσιμες προβλέψεις που βελτιώνουν τη λήψη αποφάσεων και την ποιότητα των παρεχόμενων υπηρεσιών.

Συνοψίζοντας, η επιβλεπόμενη μάθηση αποτελεί κρίσιμο παράγοντα της μηχανικής μάθησης, με καθοριστική συμβολή στην πρόοδο της βιοϊατρικής έρευνας και της ιατρικής πρακτικής, αλλά και σε πλήθος άλλων επιστημονικών και τεχνολογικών πεδίων. Η δυνατότητα αξιοποίησης μεγάλων όγκων δεδομένων για την εξαγωγή αξιόπιστων προβλέψεων καθιστά την επιβλεπόμενη μάθηση αναπόσπαστο εργαλείο της σύγχρονης επιστήμης των δεδομένων.

## 2.3 Μέθοδοι Regression

Η παλινδρόμηση (regression) αποτελεί μία από τις θεμελιώδεις τεχνικές της επιβλεπόμενης μάθησης, ο στόχος της παλινδρόμησης είναι να προβλέψει την τιμή μιας ή περισσότερων συνεχών μεταβλητών-στόχων  $t$ , δεδομένης της τιμής ενός  $D$ -διάστατου διανύσματος  $x$  μεταβλητών εισόδου [2]. Σε αντίθεση με την ταξινόμηση (classification), όπου το ζητούμενο είναι η απόδοση μιας παρατήρησης σε μία από προκαθορισμένες διακριτές κατηγορίες, η παλινδρόμηση εστιάζει στην εκτίμηση αριθμητικών τιμών. Συνοψίζοντας τις βασικές ιδιότητες των μεθόδων παλινδρόμησης, ο πίνακας 2.1 παρουσιάζει τις προσεγγίσεις που εξετάζονται για την πρόβλεψη του `recovery_time_weeks` μαζί με ενδεικτικά πλεονεκτήματα και περιορισμούς. Η αξιολόγηση των μοντέλων έγινε με δείκτες σφάλματος MAE και RMSE, με έμφαση στην ερμηνευσιμότητα μέσω τιμών SHAP. Η γραμμική παλινδρόμηση λειτουργεί ως baseline λόγω απλότητας και διαφάνειας. Τα δένδροειδή σύνολα (Random Forest, XGBoost) αξιοποιούν μη γραμμικότητες και αλληλεπιδράσεις, επιτυγχάνοντας συνήθως υψηλότερη ακρίβεια σε ετερογενή κλινικά δεδομένα. Τα νευρωνικά δίκτυα μπορούν να αποδώσουν σε μεγάλα σύνολα, απαιτούν όμως προσεκτική ρύθμιση υπερπαραμέτρων και έλεγχο υπερπροσαρμογής, καθώς και πρόσθετες τεχνικές ερμηνείας.

Πίνακας 2.1: Σύγκριση Μεθοδολογιών

Μέθοδος	Πλεονεκτήματα	Περιορισμοί
Γραμμική Παλινδρόμηση	Απλότητα, υψηλή ερμηνευσιμότητα	Μόνο γραμμικές σχέσεις
Random Forest	Αντιμέτωπη μη γραμμικότητας, αντοχή σε εκτρέψεις	Περιορισμένη ερμηνευσιμότητα
XGBoost	Υψηλή ακρίβεια, ενσωματωμένη τακτοποίηση υπερπαραμέτρων	Πολυπλοκότητα ρύθμισης, αυξημένος χρόνος εκπαίδευσης
Νευρωνικά Δίκτυα	Χειρισμός πολύπλοκων αλληλεπιδράσεων	"Μαύρο κουτί", μεγάλη ανάγκη για δεδομένα

### 2.3.1 Βασικές μέθοδοι παλινδρόμησης

Η γραμμική παλινδρόμηση (linear regression) αποτελεί το απλούστερο και πλέον διαδεδομένο μοντέλο παλινδρόμησης. Υποθέτει γραμμική σχέση μεταξύ των χαρακτηριστικών εισόδου και της μεταβλητής-στόχου, και εκφράζεται μαθηματικά από την εξίσωση 2.1

$$y = w_0 + w_1x_1 + w_2x_2 + \dots + w_nx_n \quad (2.1)$$

όπου ( $y$ ) είναι η προβλεπόμενη τιμή, ( $x_i$ ) τα χαρακτηριστικά και ( $w_i$ ) τα αντίστοιχα βάρη [5]. Η εκπαίδευση του μοντέλου βασίζεται στη βελτιστοποίηση των βαρών ώστε να ελαχιστοποιείται το σφάλμα μεταξύ των προβλέψεων και των πραγματικών τιμών, συνήθως με τη μέθοδο των ελαχίστων τετραγώνων.

Για πιο σύνθετες σχέσεις, χρησιμοποιείται η πολυωνυμική παλινδρόμηση (polynomial regression), όπου το μοντέλο περιλαμβάνει ανώτερες δυνάμεις των χαρακτηριστικών, επιτρέποντας την προσέγγιση μη γραμμικών σχέσεων. Ωστόσο, η αυξημένη πολυπλοκότητα μπορεί να οδηγήσει σε υπερπροσαρμογή (overfitting) [2].

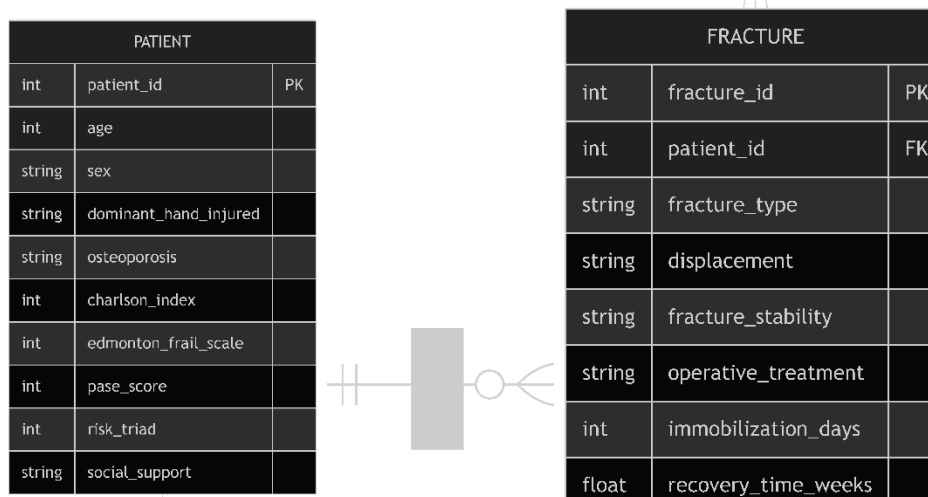
Τα δέντρα απόφασης για παλινδρόμηση (regression trees) αποτελούν μια εναλλακτική προσέγγιση, όπου ο χώρος των χαρακτηριστικών χωρίζεται σε περιοχές και η πρόβλεψη βασίζεται στον μέσο όρο των τιμών εντός κάθε περιοχής [3]. Τα δέντρα απόφασης είναι εύκολα ερμηνεύσιμα, αλλά συχνά παρουσιάζουν υπερπροσαρμογή, ειδικά όταν είναι πολύ βαθιά.

Για την αντιμετώπιση αυτού του προβλήματος, χρησιμοποιούνται ensemble μέθοδοι όπως τα Random Forests και το XGBoost, που συνδυάζουν πολλά δέντρα για να βελτιώσουν την ακρίβεια και τη σταθερότητα των προβλέψεων [5][3]. Τα Random Forests δημιουργούν πολλαπλά δέντρα απόφασης σε διαφορετικά υποσύνολα των δεδομένων, ενώ το XGBoost βασίζεται στην τεχνική του boosting, όπου κάθε νέο δέντρο διορθώνει τα σφάλματα των προηγούμενων.

Τέλος, τα νευρωνικά δίκτυα (neural networks) χρησιμοποιούνται για παλινδρόμηση όταν η σχέση μεταξύ εισόδου και εξόδου είναι ιδιαίτερα πολύπλοκη και μη γραμμική[9]. Τα δίκτυα αυτά έχουν τη δυνατότητα να προσεγγίζουν πολύπλοκες συναρτήσεις, αρκεί να διαθέτουν επαρκή δεδομένα και κατάλληλη αρχιτεκτονική.

### 2.3.2 Εφαρμογές παλινδρόμησης στην ιατρική

Όσον αφορά τον τομέα της υγείας, οι μέθοδοι παλινδρόμησης είναι απαραίτητες σε σειρά προβλημάτων στα οποία απαιτείται η ποσοτική εκτίμηση κλινικών δεικτών ή η πρόβλεψη μελλοντικών τιμών. Ενδεικτικά, η παλινδρόμηση χρησιμοποιείται για την πρόβλεψη της διάρκειας νοσηλείας ασθενών, λαμβάνοντας υπόψη δημογραφικά, κλινικά και εργαστηριακά δεδομένα. Παράλληλα, σημαντική είναι η συμβολή της στην εκτίμηση του χρόνου αποκατάστασης μετά από χειρουργικές επεμβάσεις, βοηθώντας τους γιατρούς να σχεδιάσουν εξατομικευμένα πλάνα αποθεραπείας. Για να κατανοήσουμε καλύτερα το μοντέλο των δεδομένων που χρησιμοποιείται στις προγνωστικές προσεγγίσεις, παρατίθεται το σχήμα 2.1, το οποίο παρουσιάζει το σχεσιακό διάγραμμα οντοτήτων (ER) του συνθετικού συνόλου δεδομένων που χρησιμοποιείται στη μελέτη. Το σχήμα περιλαμβάνει δύο βασικές οντότητες, PATIENT και FRACTURE, με σχέση 1-προς-N (ένας ασθενής μπορεί να εμφανίζει περισσότερα του ενός κατάγματα). Η επιλογή συνθετικών δεδομένων έγινε ως λύση ανάγκης λόγω έλλειψης προσβάσιμων πραγματικών δημόσιων δεδομένων, με στόχο την ρεαλιστική αναπαράσταση κλινικά τεκμηριωμένων συσχετίσεων.



Σχήμα 2.1: ER Diagram Συνθετικού Dataset

Επιπλέον, οι μέθοδοι παλινδρόμησης είναι χρήσιμες για την πρόβλεψη της συγκέντρωσης βιοχημικών δεικτών στο αίμα, όπως τα επίπεδα σακχάρου ή χοληστερόλης, γεγονός που διευκολύνει την παρακολούθηση της πορείας χρόνιων νοσημάτων και την έγκαιρη παρέμβαση. Άλλη εξίσου σημαντική εφαρμογή αποτελεί η εκτίμηση του κινδύνου εκ νέου εισαγωγής στο νοσοκομείο (readmission risk) ως συνεχής πιθανότητα, επιτρέποντας την καλύτερη διαχείριση των πόρων και τη βελτίωση της φροντίδας των ασθενών.

Αξίζει επίσης να σημειωθεί ότι η παλινδρόμηση χρησιμοποιείται για την πρόβλεψη της εξέλιξης χρόνιων νοσημάτων, όπως ο ρυθμός μείωσης της νεφρικής λειτουργίας σε ασθενείς με χρόνια νεφρική νόσο ή η πορεία της γλυκοζυλιωμένης αιμοσφαιρίνης (μια μορφή αιμοσφαιρίνης στην οποία έχει προσκολληθεί γλυκόζη) σε διαβητικούς ασθενείς. Μέσω αυτών των εφαρμογών, οι μέθοδοι παλινδρόμησης συμβάλλουν ουσιαστικά στη λήψη τεκμηριωμένων ιατρικών αποφάσεων, στην

εξατομίκευση της θεραπείας και στη βελτίωση της ποιότητας των υπηρεσιών υγείας που προσφέρονται στους ασθενείς [7].

Συνοψίζοντας, η παλινδρόμηση αποτελεί αναπόσπαστο εργαλείο της μηχανικής μάθησης, με καθοριστική εφαρμογή στην ανάλυση και πρόβλεψη πολύπλοκων φαινομένων, ιδιαίτερα στον τομέα της ιατρικής, όπου η ακρίβεια και η αξιοπιστία των προβλέψεων είναι ζωτικής σημασίας.

## 2.4 Αλγόριθμοι που Χρησιμοποιήθηκαν

Η ραγδαία εξέλιξη τόσο της μηχανικής μάθησης όσο και της στατιστικής ανάλυσης έχει συμβάλει στην ανάπτυξη και εφαρμογή πληθώρας μεθόδων για την πρόβλεψη και τη μοντελοποίηση πολύπλοκων φαινομένων. Στο παρόν κεφάλαιο παρουσιάζονται οι σημαντικότερες τεχνικές παλινδρόμησης και οι σύγχρονοι αλγόριθμοι που χρησιμοποιούνται ευρέως τόσο στην ακαδημαϊκή έρευνα όσο και στη βιομηχανία. Ξεκινώντας από τη γραμμική παλινδρόμηση και τις επεκτάσεις της, όπως η Ridge Regression, εξετάζονται οι βασικές αρχές, τα πλεονεκτήματα και οι περιορισμοί τους. Στη συνέχεια, αναλύονται προηγμένες μέθοδοι όπως το XGBoost και ο Random Forest, οι οποίες αξιοποιούν τη δύναμη των συνόλων και της τυχαιοποίησης για τη βελτίωση της ακρίβειας και της γενίκευσης των μοντέλων. Τέλος, παρουσιάζονται τα τεχνητά νευρωνικά δίκτυα, τα οποία, εμπνευσμένα από τη βιολογική νοημοσύνη, έχουν φέρει επανάσταση στην επίλυση σύνθετων προβλημάτων μέσω της ικανότητάς τους να μαθαίνουν πολύπλοκες, μη γραμμικές σχέσεις από τα δεδομένα.

### 2.4.1 Γραμμική Παλινδρόμηση και Ridge Regression

Η γραμμική παλινδρόμηση αποτελεί μία από τις σημαντικότερες και συχνότερα χρησιμοποιούμενες μεθόδους στην επιβλεπόμενη μάθηση και τη στατιστική ανάλυση. Ο βασικός στόχος της είναι η πρόβλεψη της τιμής μιας συνεχούς μεταβλητής-στόχου ( $Y$ ) βάσει ενός διανύσματος εισόδου ( $X = (X_1, X_2, \dots, X_p)$ ), με την υπόθεση ότι η συνάρτηση παλινδρόμησης ( $E(Y | X)$ ) είναι γραμμική ως προς τα χαρακτηριστικά [2] [5].

Η βασική μορφή του γραμμικού μοντέλου δίνεται από την εξίσωση 2.2.

$$f(X) = \beta^0 + \sum_{j=1}^p X_j \beta_j \quad (2.2)$$

όπου τα ( $\beta_j$ ) είναι οι άγνωστοι συντελεστές του μοντέλου.

Η παραπάνω εξίσωση εκφράζει ότι η προβλεπόμενη τιμή της εξόδου είναι ένας γραμμικός συνδυασμός των χαρακτηριστικών εισόδου και ενός σταθερού όρου.

Η εκτίμηση των παραμέτρων του μοντέλου γίνεται συνήθως με τη μέθοδο των ελαχίστων τετραγώνων, η οποία επιλέγει τα ( $\beta$ ) ώστε να ελαχιστοποιείται το άθροισμα των τετραγώνων των υπολοίπων (RSS), εξίσωση 2.3

$$RSS(\beta) = \sum_{i=1}^N (y_i - f(x_i))^2 = \sum_{i=1}^N (y_i - \beta_0 - \sum_{j=1}^p x_{ij} \beta_j)^2 \quad (2.3)$$

Η λύση του προβλήματος δίνεται αναλυτικά από την εξίσωση 2.4

$$\hat{\beta}_{ridge} = (X^t X)^{-1} X^t y \quad (2.4)$$

όπου ( $X$ ) είναι ο πίνακας των εισόδων και ( $y$ ) το διάνυσμα των τιμών-στόχων.

Ωστόσο σε περιπτώσεις όπου ελλοχεύει κίνδυνος υπερπροσαρμογής (overfitting) ή τα δεδομένα παρουσιάζουν πολυσυγγραμμικότητα (multicollinearity), η απλή γραμμική παλινδρόμηση είναι πιθανό να οδηγήσει σε ασταθείς ή μη γενικεύσιμες λύσεις. Για την αντιμετώπιση αυτών των προβλημάτων

εφαρμόζεται συχνά κανονικοποίηση (regularization), με πιο διαδεδομένη προσέγγιση τη Ridge Regression. Η οποία προσθέτει έναν όρο ποινής στο κριτήριο των ελαχίστων τετραγώνων, περιορίζοντας το μέγεθος των συντελεστών του μοντέλου. Το νέο κριτήριο ελαχιστοποίησης διαμορφώνεται από την εξίσωση 2.5

$$RSS_{ridge(\beta)} = \sum (y_i - f(x_i))^2 + \lambda \sum (\beta_j)^2 \quad (2.5)$$

όπου  $\lambda \geq 0$  είναι ο υπερπαραμέτρος κανονικοποίησης που ελέγχει το βαθμό ποινής.

Η λύση του προβλήματος Ridge Regression δίνεται από την εξίσωση 2.6

$$\hat{\beta}_{ridge} = (X^T X + \lambda I)^{-1} X^T y \quad (2.6)$$

Η προσθήκη του όρου  $\lambda I$  εξασφαλίζει ότι ο πίνακας προς αντιστροφή είναι πάντοτε θετικά ορισμένος, ακόμη και σε περιπτώσεις έντονης πολυσυγγραμμικότητας ή όταν το  $X^T X$  είναι ιδιόμορφο.

Η κανονικοποίηση συμβάλλει στον έλεγχο της πολυπλοκότητας του μοντέλου και στη βελτίωση της γενίκευσης σε νέα δεδομένα, καθώς συμβάλλει στη μείωση της διασποράς των εκτιμήσεων και παράλληλα περιορίζει την επίδραση των ακραίων τιμών ή των ισχυρά συσχετισμένων χαρακτηριστικών. Ωστόσο, σε αντίθεση με τη Lasso Regression, η Ridge Regression δεν οδηγεί σε ακριβώς μηδενικούς συντελεστές, επομένως δεν πραγματοποιεί επιλογή χαρακτηριστικών (feature selection).

Συμπερασματικά η γραμμική παλινδρόμηση διακρίνεται για την απλότητά της, την εύκολη ερμηνεία των συντελεστών της και την υψηλή απόδοση των υπολογισμών της. Παράλληλα, καθιστά εύκολη την κατανόηση και την ανάπτυξη πιο σύνθετων αλγορίθμων παλινδρόμησης στη μηχανική μάθηση.

## 2.4.2 XGBoost

Είναι ευρέως διαδεδομένο πως πλέον το XGBoost (Extreme Gradient Boosting) αποτελεί έναν από τους πιο σύγχρονους και αποδοτικούς αλγορίθμους μηχανικής μάθησης για προβλήματα παλινδρόμησης και ταξινόμησης. Βασίζεται στη μεθοδολογία του gradient boosting, κατά την οποία διαδοχικά απλά μοντέλα, συνήθως δέντρα αποφάσεων, συνδυάζονται με τέτοιο τρόπο ώστε κάθε νέο μοντέλο να εστιάζει στη διόρθωση των σφαλμάτων των προηγούμενων. Μέσω αυτής της διαδικασίας, το τελικό μοντέλο προκύπτει ως άθροισμα πολλών αδύναμων μοντέλων, επιτυγχάνοντας υψηλή ακρίβεια πρόβλεψης και αποτελεσματικότητα [3].

Το XGBoost προσθέτει σημαντικές βελτιώσεις σε σχέση με παλαιότερες υλοποιήσεις του gradient boosting, τόσο σε επίπεδο υπολογιστικής αποδοτικότητας όσο και σε επίπεδο γενίκευσης. Πιο συγκεκριμένα, υποστηρίζει παραλληλοποίηση κατά την εκπαίδευση (όταν μια υπολογιστική διαδικασία «σπάει» σε μικρότερα κομμάτια που εκτελούνται ταυτόχρονα (παράλληλα), συνήθως σε πολλούς επεξεργαστές ή πυρήνες, με στόχο τη σημαντική επιτάχυνση της εκτέλεσης, parallelization), βέλτιστη διαχείριση μνήμης και τεχνικές κανονικοποίησης (regularization), οι οποίες συμβάλλουν στον περιορισμό της υπερπροσαρμογής (overfitting). Επιπλέον, το XGBoost έχει την ικανότητα να διαχειρίζεται ελλιπή δεδομένα και να ενσωματώνει αυτόματα τεχνικές διαχείρισης outliers (μέθοδοι που εντοπίζουν και αντιμετωπίζουν ακραίες τιμές στα δεδομένα).

Εξίσου σημαντικό πλεονέκτημα του XGBoost αποτελεί η δυνατότητα να ερμηνεύει τα αποτελέσματα αναλύοντας τη σημασία των χαρακτηριστικών (feature importance), με αποτέλεσμα να προσφέρει πολύτιμη πληροφόρηση για τη συμβολή κάθε μεταβλητής στην τελική πρόβλεψη.

Παράδειγμα:

Έστω ότι θέλουμε να προβλέψουμε την τιμή ενός ακινήτου με χαρακτηριστικά όπως το εμβαδόν, ο αριθμός δωματίων και η τοποθεσία. Χρησιμοποιώντας το XGBoost, μπορούμε να εκπαιδεύσουμε ένα μοντέλο παλινδρόμησης, το οποίο θα συνδυάσει πολλά δέντρα αποφάσεων ώστε να ελαχιστοποιήσει το σφάλμα πρόβλεψης. Το XGBoost θα εντοπίσει αυτόματα ποια χαρακτηριστικά είναι πιο σημαντικά για την πρόβλεψη της τιμής, ενώ ταυτόχρονα θα προστατεύσει το μοντέλο από υπερπροσαρμογή μέσω των ενσωματωμένων τεχνικών regularization.

Συνοψίζοντας, το XGBoost αποτελεί μια αρκετά ισχυρή και ευέλικτη επιλογή για προβλήματα όπου απαιτείται υψηλή ακρίβεια, ταχύτητα και αποτελεσματική διαχείριση μεγάλων και πολύπλοκων συνόλων δεδομένων. Ως αποτέλεσμα αυτών, έχει καθιερωθεί ως πρότυπο εργαλείο σε πλήθος εφαρμογών της μηχανικής μάθησης και χρησιμοποιείται ευρέως τόσο στην ακαδημαϊκή έρευνα όσο και στη βιομηχανία.

### 2.4.3 Random Forest

Έχει διαπιστωθεί πως ο αλγόριθμος Random Forest αποτελεί μια από τις πιο σύγχρονες και ιδιαίτερα αποτελεσματικές μεθόδους στην επίλυση προβλημάτων ταξινόμησης και παλινδρόμησης, βασισμένη στη λογική των συνόλων (ensemble learning). Η κεντρική ιδέα είναι η δημιουργία ενός μεγάλου αριθμού δέντρων αποφάσεων, όπου καθένα από αυτά εκπαιδεύεται με τη βοήθεια της τυχαιοποίησης (τυχαίας επιλογής δειγμάτων) τόσο ως προς τα δεδομένα όσο και ως προς τα χαρακτηριστικά που χρησιμοποιούνται για τον διαχωρισμό σε κάθε κόμβο [8].

Η τυχαιοποίηση (randomization) επιτυγχάνεται με διάφορους τρόπους, όπως η μέθοδος bagging (bootstrap aggregating), όπου κάθε δέντρο εκπαιδεύεται σε ένα τυχαίο δείγμα του αρχικού συνόλου δεδομένων, και η τυχαία επιλογή υποσυνόλου χαρακτηριστικών σε κάθε διαχωρισμό του δέντρου. Αυτές οι διαδικασίες διασφαλίζουν ότι τα δέντρα του δάσους είναι μεταξύ τους όσο το δυνατόν πιο ανεξάρτητα, γεγονός που οδηγεί σε μείωση της διασποράς και βελτίωση της γενίκευσης του τελικού μοντέλου.

Η τελική πρόβλεψη του Random Forest προκύπτει από τη συλλογική ψήφο όλων των δέντρων (πλειοψηφία για ταξινόμηση, μέσος όρος για παλινδρόμηση). Ταυτόχρονα ένα ακόμη σημαντικό πλεονέκτημα της μεθόδου είναι ότι, λόγω της τυχαιοποίησης και του συνδυασμού πολλών δέντρων, το φαινόμενο της υπερπροσαρμογής (overfitting) περιορίζεται σημαντικά, ενώ παράλληλα διατηρείται υψηλή ακρίβεια πρόβλεψης.

Παράλληλα, ο Random Forest προσφέρει εσωτερικές εκτιμήσεις για το σφάλμα γενίκευσης μέσω της τεχνικής out-of-bag (OOB) error estimation, όπου για κάθε παρατήρηση χρησιμοποιούνται μόνο τα δέντρα που δεν την περιείχαν στο δείγμα εκπαίδευσης. Αυτό επιτρέπει την αξιόπιστη εκτίμηση της απόδοσης του μοντέλου χωρίς την ανάγκη ξεχωριστού συνόλου ελέγχου.

Η μέθοδος είναι επίσης ανθεκτική σε ακραίες τιμές (outliers) και θόρυβο, ενώ προσφέρει εργαλεία για την εκτίμηση της σημασίας των χαρακτηριστικών (feature importance), διευκολύνοντας επομένως την ερμηνεία των αποτελεσμάτων. Η ευελιξία, η απλότητα στην παραμετροποίηση και η δυνατότητα παραλληλοποίησης καθιστούν τον Random Forest κατάλληλο για εφαρμογές σε μεγάλα και πολύπλοκα σύνολα δεδομένων, τόσο στην ακαδημαϊκή έρευνα όσο και στη βιομηχανία.

### 2.4.4 Τεχνητά Νευρωνικά Δίκτυα (Artificial Neural Networks)

Τα τεχνητά νευρωνικά δίκτυα (Artificial Neural Networks, ANN) αποτελούν μια από τις πλέον θεμελιώδεις και ισχυρές κατηγορίες αλγορίθμων στη σύγχρονη μηχανική μάθηση και τεχνητή

νοημοσύνη, εμπνευσμένα από τη δομή και τη λειτουργία του ανθρώπινου εγκεφάλου. Ένα νευρωνικό δίκτυο αποτελείται από ένα σύνολο διασυνδεδεμένων υπολογιστικών μονάδων, τους τεχνητούς νευρώνες, οι οποίοι οργανώνονται σε διαδοχικά επίπεδα: το επίπεδο εισόδου, ένα ή περισσότερα κρυφά επίπεδα (hidden layers) και το επίπεδο εξόδου [2]. Κάθε νευρώνας λαμβάνει ως είσοδο έναν γραμμικό συνδυασμό των εξόδων των νευρώνων του προηγούμενου επιπέδου, στον οποίο εφαρμόζεται μια μη γραμμική συνάρτηση ενεργοποίησης, όπως η sigmoid, η tanh ή η ReLU (Rectified Linear Unit), επιτρέποντας στο δίκτυο να προσεγγίζει πολύπλοκες, μη γραμμικές συναρτήσεις [2].

Η εκπαίδευση των νευρωνικών δικτύων βασίζεται στη διαδικασία της οπισθοδιάδοσης (backpropagation), σε συνδυασμό με αλγορίθμους βελτιστοποίησης όπως η στοχαστική βαθμίδα καθόδου (stochastic gradient descent), ώστε να ελαχιστοποιείται μια συνάρτηση κόστους, όπως το μέσο τετραγωνικό σφάλμα ή η διασταυρούμενη εντροπία[9]. Ένα σημαντικό θεωρητικό αποτέλεσμα είναι ότι ένα feed-forward δίκτυο με ένα μόνο κρυφό επίπεδο και επαρκή αριθμό νευρώνων μπορεί να προσεγγίσει οποιαδήποτε συνεχή συνάρτηση σε συμπαγή υποσύνολα του  $R^n$ , υπό ήπιες υποθέσεις για τη συνάρτηση ενεργοποίησης [2].

Η ανάπτυξη των βαθιών νευρωνικών δικτύων (deep neural networks), τα οποία περιλαμβάνουν μεγάλο αριθμό κρυφών επιπέδων, έχει οδηγήσει σε σημαντικές προόδους σε τομείς όπως η αναγνώριση προτύπων, η επεξεργασία εικόνας και φυσικής γλώσσας, η πρόβλεψη χρονοσειρών και η βιοπληροφορική (LeCun et al., 2015). Τα βαθιά δίκτυα επιτρέπουν την αυτόματη εκμάθηση αναπαραστάσεων υψηλού επιπέδου απευθείας από τα δεδομένα, χωρίς την ανάγκη χειροκίνητης εξαγωγής χαρακτηριστικών [9].

Παρά τα σημαντικά πλεονεκτήματά τους, τα νευρωνικά δίκτυα ενέχουν και ορισμένους περιορισμούς. Απαιτούν συνήθως μεγάλο όγκο δεδομένων για αποτελεσματική εκπαίδευση, είναι υπολογιστικά απαιτητικά και συχνά χαρακτηρίζονται από περιορισμένη ερμηνευσιμότητα, καθώς λειτουργούν ως «μαύρο κουτί» (black box). Επιπλέον, η επιλογή της κατάλληλης αρχιτεκτονικής και των υπερπαραμέτρων του δικτύου αποτελεί μια πρόκληση που απαιτεί εμπειρία και πειραματισμό.

Συνοψίζοντας, τα τεχνητά νευρωνικά δίκτυα αποτελούν ένα από τα σημαντικότερα εργαλεία της σύγχρονης μηχανικής μάθησης, με διαρκώς αυξανόμενη εφαρμογή τόσο στην ακαδημαϊκή έρευνα όσο και στη βιομηχανία.

### 2.5 Ερμηνευσιμότητα Μοντέλων

Η ερμηνευσιμότητα των μοντέλων μηχανικής μάθησης αποτελεί κρίσιμο παράγοντα, ιδιαίτερα σε ευαίσθητους τομείς όπως η υγεία. Σε εφαρμογές ιατρικής διάγνωσης και πρόγνωσης, η δυνατότητα κατανόησης των αποφάσεων ενός μοντέλου είναι απαραίτητη τόσο για την ενίσχυση της εμπιστοσύνης των επαγγελματιών υγείας όσο και για τη διασφάλιση της ασφάλειας των ασθενών. Η ερμηνευσιμότητα επιτρέπει τον εντοπισμό πιθανών σφαλμάτων, την αποκάλυψη προκαταλήψεων στα δεδομένα και τη συμμόρφωση με κανονιστικά πλαίσια, ενώ διευκολύνει τη συνεργασία μεταξύ ανθρώπου και μηχανής στη λήψη αποφάσεων[10][11].

#### 2.5.1 Σημασία Χαρακτηριστικών

Η σημασία χαρακτηριστικών (feature importance) αναφέρεται στη σχετική συμβολή κάθε χαρακτηριστικού στην τελική πρόβλεψη του μοντέλου. Σε αλγορίθμους όπως τα δέντρα απόφασης και τα Random Forests, η σημασία υπολογίζεται συνήθως με βάση τη μείωση της αβεβαιότητας (π.χ. μείωση της εντροπίας ή του Gini index) ή την αύξηση της ακρίβειας κατά τη διάσπαση των κόμβων [8] [3]. Η ερμηνεία της σημασίας των χαρακτηριστικών βοηθά στην κατανόηση των παραγόντων που

επιρεάζουν το αποτέλεσμα, επιτρέποντας την αναγνώριση των σημαντικότερων μεταβλητών για το υπό μελέτη πρόβλημα.


Ωστόσο, η παραδοσιακή σημασία χαρακτηριστικών παρέχει κυρίως συνολική εικόνα για το μοντέλο και συχνά δεν λαμβάνει υπόψη αλληλεπιδράσεις μεταξύ χαρακτηριστικών ή την επίδραση σε μεμονωμένες προβλέψεις.

### 2.5.2 Τιμές SHAP

Οι τιμές SHAP (SHapley Additive exPlanations) αποτελούν μια σύγχρονη και θεωρητικά θεμελιωμένη μέθοδο ερμηνείας των προβλέψεων, βασισμένη στη θεωρία παιγνίων [35] [11] [10]. Οι τιμές SHAP επιτρέπουν την ποσοτικοποίηση της συνεισφοράς κάθε χαρακτηριστικού σε κάθε μεμονωμένη πρόβλεψη, προσφέροντας τόσο συνολική όσο και τοπική ερμηνεία. Σε αντίθεση με τη συνολική σημασία χαρακτηριστικών, οι τιμές SHAP αποδίδουν σε κάθε χαρακτηριστικό μια μοναδική τιμή για κάθε παρατήρηση, λαμβάνοντας υπόψη όλες τις δυνατές αλληλεπιδράσεις μεταξύ χαρακτηριστικών.

Η μέθοδος SHAP διασφαλίζει ιδιότητες όπως η αθροιστικότητα (additivity) και η συνέπεια (consistency), καθιστώντας την ιδιαίτερα αξιόπιστη για την ερμηνεία πολύπλοκων μοντέλων. Επιπλέον, η οπτικοποίηση των τιμών SHAP μέσω διαγραμμάτων (όπως τα summary plots και τα dependence plots) επιτρέπει την εύκολη κατανόηση της επίδρασης κάθε χαρακτηριστικού τόσο σε επίπεδο συνόλου όσο και σε επίπεδο μεμονωμένων προβλέψεων.

Ως παράδειγμα ερμηνείας, στο σχήμα 2.2 παρουσιάζεται SHAP dependence plot για το χαρακτηριστικό age ως προς την πρόβλεψη του recovery\_time\_weeks. Ο οριζόντιος άξονας δείχνει την πραγματική τιμή της ηλικίας και ο κατακόρυφος τη συνεισφορά της στην πρόβλεψη (τιμή SHAP, σε εβδομάδες). Θετικές τιμές SHAP αυξάνουν την εκτίμηση του χρόνου αποκατάστασης, αρνητικές την μειώνουν. Παρατηρείται μονοτονική αύξηση της συνεισφοράς με την ηλικία, με μεγαλύτερη διασπορά στις υψηλότερες τιμές, γεγονός που υποδηλώνει πιθανές αλληλεπιδράσεις με άλλα χαρακτηριστικά.



Σχήμα 2.2 : SHAP dependence plot

Ένα summary plot SHAP απεικονίζει τη συνολική επίδραση κάθε χαρακτηριστικού σε όλες τις προβλέψεις του μοντέλου, επιτρέποντας τον εντοπισμό των σημαντικότερων χαρακτηριστικών και της κατεύθυνσης της επίδρασής τους (θετική ή αρνητική). Τα dependence plots δείχνουν πώς η τιμή ενός χαρακτηριστικού επηρεάζει τη συνεισφορά του στην πρόβλεψη, λαμβάνοντας υπόψη πιθανές αλληλεπιδράσεις με άλλα χαρακτηριστικά.

### 2.5.3 Σύγκριση Feature Importance και SHAP

Η βασική διαφορά μεταξύ παραδοσιακής σημασίας χαρακτηριστικών και τιμών SHAP έγκειται στο επίπεδο ανάλυσης και στην ερμηνευτική ισχύ. Ενώ η feature importance παρέχει συνολική πληροφόρηση για το μοντέλο, οι τιμές SHAP προσφέρουν λεπτομερή, τοπική ερμηνεία για κάθε μεμονωμένη πρόβλεψη, λαμβάνοντας υπόψη τις αλληλεπιδράσεις μεταξύ χαρακτηριστικών και διασφαλίζοντας θεωρητική ορθότητα.

Συνοψίζοντας, η ερμηνευσιμότητα των μοντέλων μέσω μεθόδων όπως η feature importance και οι τιμές SHAP είναι απαραίτητη για την υπεύθυνη και αξιόπιστη εφαρμογή της μηχανικής μάθησης στην υγεία και σε άλλους κρίσιμους τομείς.

## 2.6 Επίλογος

Στο παρόν κεφάλαιο παρουσιάστηκαν οι βασικότερες μέθοδοι και αλγόριθμοι επιβλεπόμενης μάθησης που χρησιμοποιούνται ευρέως στη σύγχρονη ανάλυση δεδομένων και τη μηχανική μάθηση. Ξεκινώντας από τη γραμμική παλινδρόμηση και τις επεκτάσεις της, όπως η Ridge Regression, αναδείχθηκαν τα πλεονεκτήματα και οι περιορισμοί των κλασικών στατιστικών προσεγγίσεων. Στη συνέχεια, εξετάστηκαν προηγμένες τεχνικές όπως το XGBoost και ο Random Forest, οι οποίες αξιοποιούν τη δύναμη των συνόλων και της τυχαιοποίησης για τη βελτίωση της ακρίβειας και της γενίκευσης των μοντέλων. Ιδιαίτερη έμφαση δόθηκε στα τεχνητά νευρωνικά δίκτυα, τα οποία έχουν φέρει επανάσταση στην επίλυση σύνθετων προβλημάτων, καθώς και στις Μηχανές Υποστήριξης Διανυσμάτων, που προσφέρουν υψηλή ακρίβεια και θεωρητική εγκυρότητα.

Τέλος, αναλύθηκε η σημασία της ερμηνευσιμότητας των μοντέλων, με έμφαση σε μεθόδους όπως η σημασία χαρακτηριστικών (feature importance) και οι τιμές SHAP, οι οποίες καθιστούν δυνατή την κατανόηση και την αξιολόγηση των αποφάσεων των αλγορίθμων, ιδιαίτερα σε κρίσιμους τομείς όπως η υγεία. Συνολικά, το κεφάλαιο αυτό παρέχει το απαραίτητο θεωρητικό υπόβαθρο και τα εργαλεία για την κατανόηση και την εφαρμογή των σύγχρονων μεθόδων μηχανικής μάθησης σε πραγματικά προβλήματα.

## Κεφάλαιο 3ο: Ανασκόπηση Βιβλιογραφίας

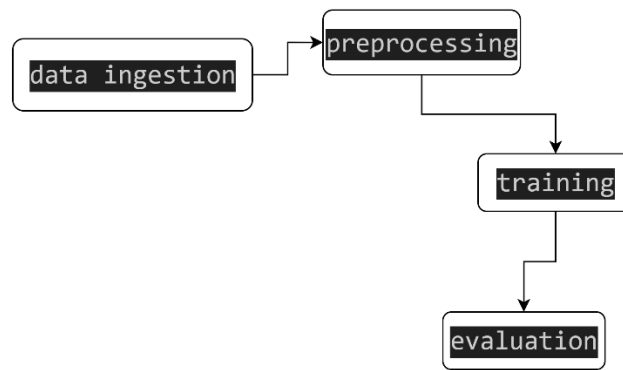
Είναι γνωστό πως η πρόβλεψη της αποκατάστασης ασθενών μετά από ορθοπεδικές κακώσεις αποτελεί ένα από τα πιο σημαντικά και σύνθετα ζητήματα στον τομέα της ιατρικής. Η ακριβής εκτίμηση του χρόνου αποκατάστασης συμβάλλει καθοριστικά στη βελτιστοποίηση της θεραπείας, της φροντίδας και στη διαχείριση των διαθέσιμων πόρων. Παρά την πρόοδο που έχει σημειωθεί τα τελευταία χρόνια στην ανάπτυξη μεθόδων πρόβλεψης, η αξιοποίηση των δεδομένων και η εφαρμογή προηγμένων αλγορίθμων μηχανικής μάθησης παραμένουν προκλήσεις, κυρίως λόγω της ετερογένειας των πληθυσμών, της ποικιλομορφίας των κλινικών παραμέτρων και της περιορισμένης διαθεσιμότητας αξιόπιστων βάσεων δεδομένων.

Στο παρόν κεφάλαιο απεικονίζονται η σχετική βιβλιογραφία και οι υπάρχουσες μελέτες που αφορούν την πρόβλεψη της αποκατάστασης μετά από κατάγματα. Επίσης παρουσιάζονται οι κυριότερες βάσεις δεδομένων και οι μελέτες που έχουν δημοσιευθεί στον τομέα αυτό, καθώς και τα προβλήματα που σχετίζονται με την έλλειψη επαρκών και ποιοτικών δεδομένων. Επιπλέον, επισημαίνεται το κίνητρο για τη δημιουργία συνθετικών συνόλων δεδομένων, όπως και η σχετική εμπειρία από μελέτες σε άλλες παθήσεις. Τέλος, πραγματοποιείται μια συνολική αποτίμηση της υπάρχουσας γνώσης και των προκλήσεων που παραμένουν ανοιχτές στον τομέα της πρόβλεψης αποκατάστασης.

### 3.1 Πρόβλεψη Αποκατάστασης

Η πρόβλεψη της πορείας αποκατάστασης ασθενών μετά από ορθοπεδικά κατάγματα ή άλλες σοβαρές παθήσεις αποτελεί σημαντικό παράγοντα τόσο για την κλινική πράξη όσο και για την επιστημονική έρευνα. Τα τελευταία χρόνια, η ανάπτυξη της μηχανικής μάθησης και η συνεχής αύξηση στη διαθεσιμότητα κλινικών δεδομένων καθιστούν αναγκαία την δημιουργία και εφαρμογή προηγμένων αλγορίθμων πρόβλεψης, οι οποίοι διασφαλίζουν μεγαλύτερη ακρίβεια και αξιοπιστία σε σύγκριση με τις παραδοσιακές στατιστικές μεθόδους. Σε αυτόν τον τομέα, πληθώρα ερευνητικών εργασιών έχουν εστιάσει στη χρήση τεχνικών μηχανικής μάθησης για την πρόβλεψη του χρόνου αποκατάστασης, τόσο σε κατάγματα όσο και σε άλλες παθολογικές καταστάσεις, αναδεικνύοντας τις δυνατότητες αλλά και τους περιορισμούς των σύγχρονων προσεγγίσεων. Το Σχήμα 3.1 απεικονίζει τον κύκλο εργασιών (pipeline) της μελέτης: data ingestion, preprocessing, training και evaluation. Στο πλαίσιο της εργασίας, το στάδιο συλλογής υλοποιήθηκε με συνθετικό σύνολο δεδομένων λόγω έλλειψης πρόσβασης σε κατάλληλα πραγματικά δημόσια δεδομένα, τα υπόλοιπα στάδια ακολουθούν βέλτιστες πρακτικές. Η αξιολόγηση των μοντέλων έγινε με MAE/RMSE και ανάλυση ερμηνευσιμότητας (τιμές SHAP), με πρόβλεψη για μελλοντική εξωτερική επικύρωση σε πραγματικά δεδομένα.

- Data ingestion: ορισμός/τεκμηρίωση χαρακτηριστικών, σχήμα δεδομένων, διαχωρισμός train/test.
- Preprocessing: καθαρισμός ελλειπόντων, κωδικοποίηση κατηγορικών, κλιμάκωση/κανονικοποίηση, χειρισμός ανισορροπίας.
- Training: επιλογή αλγορίθμων (Linear, Random Forest, XGBoost, NN), ρύθμιση υπερπαραμέτρων με cross-validation.
- Evaluation: MAE, RMSE, calibration, SHAP, ανάλυση σφαλμάτων/ανθεκτικότητας.



Σχήμα 3.1: Pipeline Μηχανικής Μάθησης

### 3.1.1 Επισκόπηση Εργασιών σε Κατάγματα

Πρόσφατα, η εφαρμογή αλγορίθμων μηχανικής μάθησης στην πρόβλεψη της αποκατάστασης μετά από κατάγματα καθίσταται ολοένα και συχνότερη, με στόχο τη βελτιστοποίηση και υποστήριξη της θεραπευτικής αντιμετώπισης των ασθενών. Ως εκ τούτου πολλαπλές μελέτες εξετάζουν τον χρόνο αποκατάστασης από κατάγματα ισχίου, άνω και κάτω άκρου, αξιοποιώντας διαφορετικές τεχνικές μηχανικής μάθησης και ποικίλα σύνολα δεδομένων.

Σε μελέτη των Kim et al. (2021), αξιοποιήθηκε η χρήση αλγορίθμων όπως τα Random Forests, τα Support Vector Machines (SVM) και τα νευρωνικά δίκτυα για την πρόβλεψη της λειτουργικής αποκατάστασης μετά από κάταγμα ισχίου σε ηλικιωμένους ασθενείς. Τα δεδομένα που χρησιμοποιήθηκαν περιλάμβαναν δημογραφικά στοιχεία, κλινικές παραμέτρους, εργαστηριακές τιμές και λειτουργικές κλίμακες κατά την εισαγωγή. Τα αποτελέσματα έδειξαν ότι τα μοντέλα μηχανικής μάθησης υπερέχουν σε ακρίβεια σε σύγκριση με τις παραδοσιακές στατιστικές μεθόδους, με το Random Forest να παρουσιάζει την υψηλότερη ευαισθησία και ειδικότητα. Ωστόσο, οι συγγραφείς επισημαίνουν ως τροχοπέδη το σχετικά μικρό μέγεθος δείγματος και την ετερογένεια των δεδομένων.

Αντίστοιχα, στη μελέτη των Wang et al. (2020), εφαρμόστηκαν αλγόριθμοι XGBoost και πολυεπίπεδα νευρωνικά δίκτυα για την πρόβλεψη της έκβασης μετά από κάταγμα κερκίδας. Τα δεδομένα προήλθαν από ηλεκτρονικούς ιατρικούς φακέλους και περιλάμβαναν κλινικά, απεικονιστικά και λειτουργικά χαρακτηριστικά. Τα μοντέλα πέτυχαν υψηλή ακρίβεια πρόβλεψης, με το XGBoost να υπερέχει σε ταχύτητα και ερμηνευσιμότητα. Παρά τα ενθαρρυντικά αποτελέσματα, οι συγγραφείς αναφέρουν ως περιορισμό την έλλειψη εξωτερικής επικύρωσης και την πιθανή ύπαρξη προκαταλήψεων στα δεδομένα.

Επιπροσθέτως, στη συστηματική ανασκόπηση των Ali et al. (2024), εξετάστηκαν διάφορες εφαρμογές μηχανικής μάθησης στην πρόβλεψη επιπλοκών και λειτουργικής αποκατάστασης μετά από κατάγματα άνω και κάτω άκρου. Οι συχνότερα χρησιμοποιούμενοι αλγόριθμοι ήταν τα Random Forests, τα SVM και τα βαθιά νευρωνικά δίκτυα (Deep Neural Networks). Τα δεδομένα προέρχονταν κυρίως από βάσεις δεδομένων πολλαπλών κέντρων και ηλεκτρονικούς φακέλους υγείας. Τα αποτελέσματα υπογράμμισαν τη δυνατότητα των μοντέλων να εντοπίζουν ασθενείς υψηλού κινδύνου για καθυστερημένη αποκατάσταση ή επιπλοκές, διευκολύνοντας την έγκαιρη παρέμβαση. Ωστόσο, οι συγγραφείς τονίζουν την ανάγκη για μεγαλύτερα και ετερογενή δείγματα, καθώς και για βελτίωση της ερμηνευσιμότητας των μοντέλων.

Τέλος, στη μελέτη των Asadi et al. (2014), η εφαρμογή αλγορίθμων SVM και Random Forest για την πρόβλεψη της λειτουργικής αποκατάστασης μετά από κάταγμα ισχίου ανέδειξε τη σημασία της ενσωμάτωσης πολυπαραγοντικών δεδομένων (δημογραφικά, κλινικά, απεικονιστικά). Τα μοντέλα

μηχανικής μάθησης παρουσίασαν υψηλότερη ακρίβεια σε σχέση με τα παραδοσιακά scores, ωστόσο η γενικευσιμότητα των αποτελεσμάτων περιορίζεται από τη μονοκεντρική φύση της μελέτης.

Συνοψίζοντας, η χρήση μεθόδων μηχανικής μάθησης στην πρόβλεψη αποκατάστασης μετά από κατάγματα παρουσιάζει σημαντικές προοπτικές, με τα μοντέλα Random Forest, SVM, XGBoost και νευρωνικά δίκτυα να κυριαρχούν στη βιβλιογραφία. Παρά τα ενθαρρυντικά αποτελέσματα, οι κύριοι περιορισμοί αφορούν το μέγεθος και την ποιότητα των δεδομένων, την ετερογένεια των πληθυσμών και την ανάγκη για εξωτερική επικύρωση και ερμηνευσιμότητα των μοντέλων.

### 3.1.2 Επισκόπηση Εργασιών σε Άλλες Παθήσεις

Η χρήση αλγορίθμων μηχανικής μάθησης για την πρόβλεψη της αποκατάστασης έχει επεκταθεί σημαντικά και σε άλλες παθολογικές καταστάσεις, πέρα από τα ορθοπεδικά κατάγματα, όπως το εγκεφαλικό επεισόδιο, τα καρδιαγγειακά νοσήματα και οι νευρολογικές διαταραχές. Σε αυτές τις περιπτώσεις, η πρόβλεψη της λειτουργικής αποκατάστασης και της έκβασης της θεραπείας αποτελεί κρίσιμο παράγοντα για τον σχεδιασμό της φροντίδας και την κατανομή των πόρων.

Ενδεικτικά, στη μελέτη των Wang et al. (2020), εφαρμόστηκαν αλγόριθμοι μηχανικής μάθησης, όπως τα Random Forests και τα νευρωνικά δίκτυα, για την πρόβλεψη της έκβασης σε ασθενείς με οξύ ισχαιμικό εγκεφαλικό επεισόδιο. Τα μοντέλα αυτά αξιοποίησαν κλινικά, απεικονιστικά και δημογραφικά δεδομένα, επιτυγχάνοντας υψηλή ακρίβεια πρόβλεψης της λειτουργικής αποκατάστασης. Παρόμοια, στη μελέτη των Asadi et al. (2014), η χρήση SVM και Random Forests για την πρόβλεψη της αποκατάστασης μετά από ενδαρτηριακή θεραπεία σε εγκεφαλικό επεισόδιο ανέδειξε την υπεροχή των μοντέλων μηχανικής μάθησης έναντι των παραδοσιακών κλινικών δεικτών.

Στον τομέα των καρδιαγγειακών νοσημάτων, οι Shickel et al. (2018) παρουσίασαν μια ανασκόπηση των εφαρμογών βαθιάς μάθησης (deep learning) στην ανάλυση ηλεκτρονικών ιατρικών φακέλων για την πρόβλεψη της αποκατάστασης και της επιβίωσης μετά από καρδιακά επεισόδια. Τα deep neural networks επέτρεψαν την ενσωμάτωση μεγάλου όγκου ετερογενών δεδομένων, βελτιώνοντας την ακρίβεια και την εξατομίκευση των προβλέψεων.

Αντίστοιχα, στη νευρολογική αποκατάσταση, οι Senders et al. (2018) ανέλυσαν τη χρήση αλγορίθμων μηχανικής μάθησης για την πρόβλεψη της έκβασης σε ασθενείς με τραυματισμούς του κεντρικού νευρικού συστήματος. Τα αποτελέσματα έδειξαν ότι τα μοντέλα μηχανικής μάθησης μπορούν να εντοπίσουν ασθενείς υψηλού κινδύνου για φτωχή αποκατάσταση, διευκολύνοντας την έγκαιρη παρέμβαση.

Συγκριτικά με τα κατάγματα, οι μελέτες σε άλλες παθήσεις παρουσιάζουν παρόμοιες προκλήσεις, όπως η ετερογένεια των δεδομένων, η ανάγκη για μεγάλα και ποιοτικά δείγματα, καθώς και η ερμηνευσιμότητα των μοντέλων. Ωστόσο, η πολυπλοκότητα των δεδομένων στις νευρολογικές και καρδιαγγειακές παθήσεις συχνά απαιτεί τη χρήση πιο σύνθετων αλγορίθμων, όπως τα βαθιά νευρωνικά δίκτυα. Παρά τις διαφορές στη φύση των δεδομένων και των εκβάσεων, τα ευρήματα υπογραμμίζουν τη δυναμική της μηχανικής μάθησης στην πρόβλεψη της αποκατάστασης σε ένα ευρύ φάσμα κλινικών καταστάσεων, ενώ αναδεικνύουν την ανάγκη για περαιτέρω έρευνα με στόχο τη βελτίωση της γενικευσιμότητας και της ερμηνευσιμότητας των μοντέλων.

### 3.1.3 Σύνοψη και Κενά στη Βιβλιογραφία

Συνοψίζοντας, η εφαρμογή αλγορίθμων μηχανικής μάθησης στην πρόβλεψη της αποκατάστασης μετά από κατάγματα και άλλες παθήσεις προσφέρει σημαντικές δυνατότητες για τη βελτίωση της ακρίβειας και της εξατομίκευσης των κλινικών προβλέψεων [12] [13] [14]. Τα μοντέλα όπως τα Random Forests, τα SVM και τα βαθιά νευρωνικά δίκτυα φέρουν υψηλές επιδόσεις σε διάφορα κλινικά σενάρια, αξιοποιώντας πολυπαραγοντικά και ετερογενή δεδομένα [15][16]. Ωστόσο, η υπάρχουσα βιβλιογραφία παρουσιάζει σημαντικά κενά, όπως η έλλειψη μεγάλων και αντιπροσωπευτικών συνόλων δεδομένων, η περιορισμένη εξωτερική επικύρωση των μοντέλων και η ανεπαρκής ερμηνευσιμότητα των αλγορίθμων [17]. Επιπλέον, η ετερογένεια των πληθυσμών και των κλινικών παραμέτρων εμποδίζει τη γενίκευση των αποτελεσμάτων στην καθημερινή κλινική πράξη. Συνεπώς, κρίνεται αναγκαία η περαιτέρω έρευνα με έμφαση στη συλλογή και ανάλυση μεγάλων, δεδομένων πολλαπλών κέντρων, στην ανάπτυξη ερμηνεύσιμων μοντέλων και στην ενσωμάτωση της μηχανικής μάθησης στην κλινική λήψη αποφάσεων, ώστε τα μοντέλα να προσφέρουν αξιοπιστία και να διευκολύνουν τη σύγχρονη ιατρική πρακτική.

## 3.2 Βάσεις Δεδομένων και Μελέτες σε Κατάγματα

Παράλληλα αξίζει να σημειωθεί πως για την πρόοδο της έρευνας στον τομέα των καταγμάτων και της αποκατάστασης σημαντικό παράγοντα αποτελούν οι αξιόπιστες και εκτενείς βάσεις δεδομένων. Η συλλογή, η οργάνωση και η ανάλυση μεγάλου όγκου ιατρικών δεδομένων διευκολύνουν την ανάπτυξη προηγμένων αλγορίθμων μηχανικής μάθησης, επιτρέποντας την πρόβλεψη του αποτελέσματος, την αναγνώριση παραγόντων κινδύνου και τη βελτιστοποίηση της θεραπευτικής αγωγής. Τα τελευταία χρόνια, η δημιουργία εθνικών και διεθνών μητρώων, καθώς και η αξιοποίηση ηλεκτρονικών ιατρικών φακέλων, έχουν βελτιώσει σημαντικά τη δυνατότητα διεξαγωγής πολυκεντρικών μελετών μεγάλης κλίμακας. Ωστόσο, η ετερογένεια των δεδομένων, τα ζητήματα ποιότητας και η περιορισμένη διαλειτουργικότητα μεταξύ διαφορετικών πηγών εξακολουθούν να αποτελούν σημαντικές προκλήσεις. Στο παρόν υποκεφάλαιο παρουσιάζονται οι κυριότερες διαθέσιμες βάσεις δεδομένων που χρησιμοποιούνται στη μελέτη των καταγμάτων, καθώς και ενδεικτικές μελέτες που αξιοποίησαν αυτά τα δεδομένα για την πρόβλεψη και την ανάλυση της αποκατάστασης.

### 3.2.1 Παρουσίαση Κύριων Βάσεων Δεδομένων

Η πρόοδος της έρευνας στον τομέα των καταγμάτων και της αποκατάστασης επηρεάζεται καθοριστικά από τη διαθεσιμότητα και την ποιότητα των βάσεων δεδομένων που συλλέγουν και οργανώνουν κλινικές πληροφορίες μεγάλης κλίμακας. Κατά την τελευταία χρονική περίοδο, η δημιουργία εθνικών και διεθνών μητρώων, όπως και η αξιοποίηση ηλεκτρονικών ιατρικών φακέλων, έχουν ενισχύσει σημαντικά τη δυνατότητα διεξαγωγής μελετών πολλαπλών κέντρων και την ανάπτυξη προηγμένων αλγορίθμων μηχανικής μάθησης [12][18].

Μεταξύ των σημαντικότερων βάσεων δεδομένων συγκαταλέγονται το Swedish Fracture Register (SFR), το οποίο αποτελεί ένα από τα μεγαλύτερα εθνικά μητρώα καταγμάτων παγκοσμίως, καταγράφοντας πάνω από 100.000 περιστατικά με λεπτομερή κλινικά, δημογραφικά και θεραπευτικά δεδομένα[18]. Αντίστοιχα, το UK National Hip Fracture Database (NHFD) παρέχει εκτεταμένες πληροφορίες για ασθενείς με κατάγματα ισχίου στο Ηνωμένο Βασίλειο, διευκολύνοντας την ανάλυση παραγόντων κινδύνου, την αξιολόγηση της ποιότητας φροντίδας και την πρόβλεψη εκβάσεων.

Στις Ηνωμένες Πολιτείες, το National Surgical Quality Improvement Program (NSQIP) και το National Inpatient Sample (NIS) αποτελούν πολύτιμες πηγές δεδομένων για την ανάλυση μεγάλου αριθμού

περιστατικών, επιτρέποντας τη μελέτη της επίπτωσης, των επιπλοκών και των αποτελεσμάτων μετά από χειρουργικές επεμβάσεις σε κατάγματα [12]. Επιπλέον, η βάση MIMIC-III (Medical Information Mart for Intensive Care) παρέχει ανοιχτή πρόσβαση σε ανωνυμοποιημένα δεδομένα εντατικής θεραπείας, τα οποία μπορούν να αξιοποιηθούν για την ανάλυση ορθοπαιδικών περιστατικών σε βαρέως πάσχοντες ασθενείς [19].

Η ύπαρξη τέτοιων βάσεων δεδομένων επιτρέπει τη διενέργεια αναδρομικών και προοπτικών μελετών, τη σύγκριση θεραπευτικών στρατηγικών και την ανάπτυξη και επικύρωση προγνωστικών μοντέλων με τη χρήση τεχνικών μηχανικής μάθησης. Ωστόσο, η ετερογένεια των δεδομένων, οι διαφορές στα πρωτόκολλα συλλογής και η ανάγκη για διαλειτουργικότητα μεταξύ διαφορετικών συστημάτων παραμένουν σημαντικές προκλήσεις για την αξιοποίηση του πλήρους δυναμικού αυτών των πηγών [20].

### 3.2.2 Ανάλυση Ενδεικτικών Μελετών

Η αξιοποίηση μεγάλων και αξιόπιστων βάσεων δεδομένων επιτρέπει την ανάπτυξη και επικύρωση προηγμένων μοντέλων μηχανικής μάθησης για την πρόβλεψη εκβάσεων σε ασθενείς με κατάγματα. Ενδεικτικά, το Swedish Fracture Register (SFR) έχει χρησιμοποιηθεί σε πληθώρα μελετών για την ανάλυση παραγόντων κινδύνου και την πρόβλεψη λειτουργικής αποκατάστασης μετά από κατάγματα. Στη μελέτη των Wennergren et al. (2018), η ανάλυση άνω των 100.000 καταγεγραμμένων περιστατικών επέτρεψε την ταυτοποίηση δημογραφικών και κλινικών παραγόντων που σχετίζονται με την πρόγνωση, ενώ η μεγάλη ετερογένεια του δείγματος ενίσχυσε τη γενικευσιμότητα των ευρημάτων.

Αντίστοιχα, το UK National Hip Fracture Database (NHFD) έχει αξιοποιηθεί για την ανάπτυξη προγνωστικών μοντέλων σχετικά με τη θνητότητα, τη διάρκεια νοσηλείας και τη λειτουργική αποκατάσταση μετά από κατάγματα ισχίου. Μελέτες που βασίστηκαν σε δεδομένα του NHFD ανέδειξαν τη σημασία παραγόντων όπως η ηλικία, οι συνοσηρότητες και η προεγχειρητική λειτουργική κατάσταση στην πρόβλεψη της έκβασης, ενώ η μεγάλη κλίμακα της βάσης επέτρεψε την επικύρωση των μοντέλων σε διαφορετικούς πληθυσμούς.

Στις Ηνωμένες Πολιτείες, η ανάλυση δεδομένων από το National Surgical Quality Improvement Program (NSQIP) και το National Inpatient Sample (NIS) έχει οδηγήσει στην ανάπτυξη μοντέλων για την πρόβλεψη επιπλοκών, επανεισαγωγών και θνητότητας μετά από χειρουργική αντιμετώπιση καταγμάτων [12]. Τα μοντέλα αυτά, συχνά βασισμένα σε αλγορίθμους όπως τα Random Forests και τα Support Vector Machines, έχουν επιτύχει υψηλή ακρίβεια, ωστόσο η ετερογένεια των δεδομένων και η απουσία λεπτομερών κλινικών παραμέτρων αποτελούν περιορισμούς για την περαιτέρω βελτίωση της προγνωστικής τους ικανότητας.

Επιπλέον, η βάση MIMIC-III έχει χρησιμοποιηθεί για την ανάλυση ορθοπαιδικών περιστατικών σε μονάδες εντατικής θεραπείας, επιτρέποντας τη μελέτη της επίδρασης παραγόντων όπως η σοβαρότητα της νόσου και οι συνοσηρότητες στην έκβαση των ασθενών [19]. Η ανοιχτή πρόσβαση και η λεπτομερής καταγραφή δεδομένων καθιστούν τη MIMIC-III πολύτιμο εργαλείο για την ανάπτυξη και δοκιμή νέων αλγορίθμων μηχανικής μάθησης.

Τέλος, μελέτες που συνδύασαν δεδομένα από διαφορετικές βάσεις ή εφάρμοσαν πολυπαραγοντικά μοντέλα ανέδειξαν τη σημασία της διαλειτουργικότητας και της ένωσης των δεδομένων για την αύξηση της ακρίβειας και της γενικευσιμότητας των προγνωστικών εργαλείων [20][12]. Παρά τα ενθαρρυντικά αποτελέσματα, παραμένει αναγκαία η περαιτέρω βελτίωση της ποιότητας των δεδομένων, η εξωτερική επικύρωση των μοντέλων και η ενίσχυση της ερμηνευσιμότητας των αλγορίθμων για την ασφαλή ενσωμάτωσή τους στην κλινική πράξη.

### 3.2.3 Συζήτηση – Προκλήσεις και Προοπτικές

Παρά τη σημαντική πρόοδο που έχει σημειωθεί στη συλλογή και αξιοποίηση μεγάλων βάσεων δεδομένων για τη μελέτη των καταγμάτων, εξακολουθούν να υφίστανται σημαντικές προκλήσεις που περιορίζουν την πλήρη αξιοποίηση του δυναμικού τους. Η ετερογένεια των δεδομένων, τόσο ως προς τη δομή όσο και ως προς το περιεχόμενο, αποτελεί έναν από τους βασικότερους περιορισμούς, καθώς διαφορετικά κέντρα και χώρες εφαρμόζουν ποικίλα πρωτόκολλα συλλογής και καταγραφής πληροφοριών [18][12]. Επιπλέον, η ύπαρξη ελλιπών ή ανακριβών δεδομένων, η απουσία τυποποιημένων ορισμών για τις εκβάσεις και η περιορισμένη διαλειτουργικότητα μεταξύ διαφορετικών συστημάτων δυσχεραίνουν τη σύγκριση και τη συνδυασμένη ανάλυση των αποτελεσμάτων [20].

Ένα ακόμη σημαντικό ζήτημα αφορά την προστασία των προσωπικών δεδομένων και τη διασφάλιση της ιδιωτικότητας των ασθενών, ειδικά όταν πρόκειται για τη διασύνδεση και την ανταλλαγή δεδομένων σε διεθνές επίπεδο [19]. Παράλληλα, η ανάγκη για εξωτερική επικύρωση των προγνωστικών μοντέλων και η ενίσχυση της ερμηνευσιμότητας των αλγορίθμων μηχανικής μάθησης παραμένουν ανοιχτά ερευνητικά πεδία, καθώς η εφαρμογή τους στην κλινική πράξη απαιτεί υψηλά επίπεδα αξιοπιστίας και διαφάνειας [12].

Ωστόσο, οι προοπτικές που διανοίγονται είναι ιδιαίτερα ενθαρρυντικές. Η συνεχής βελτίωση της ποιότητας και της πληρότητας των δεδομένων, η ανάπτυξη διαλειτουργικών και ανοιχτών βάσεων, καθώς και η ενσωμάτωση πολυτροπικών πληροφοριών (κλινικά, απεικονιστικά, γενετικά δεδομένα) αναμένεται να ενισχύσουν σημαντικά τη δυνατότητα ανάπτυξης και επικύρωσης προηγμένων προγνωστικών εργαλείων [20]. Η διεπιστημονική συνεργασία μεταξύ κλινικών ιατρών, επιστημόνων δεδομένων και μηχανικών πληροφορικής αποτελεί βασική προϋπόθεση για την επιτυχή ενσωμάτωση των τεχνολογιών αυτών στην καθημερινή κλινική πρακτική, με τελικό στόχο τη βελτίωση της φροντίδας και της έκβασης των ασθενών με κατάγματα.

### 3.3 Έλλειψη Διαθέσιμων Δεδομένων και Συνθετικό Dataset

Βασική προϋπόθεση για την ανάπτυξη αλγορίθμων μηχανικής μάθησης στον τομέα της υγείας αποτελεί η ύπαρξη επαρκών και κυρίως ποιοτικών δεδομένων. Ωστόσο, η συλλογή πραγματικών κλινικών δεδομένων συχνά συναντά σημαντικά εμπόδια, όπως νομικούς και ηθικούς περιορισμούς, ετερογένεια στις διαδικασίες καταγραφής, ελλιπή τεκμηρίωση και περιορισμένη πρόσβαση σε μεγάλους πληθυσμούς ασθενών. Τα παραπάνω προβλήματα εμφανίζουν δυσκολίες τόσο στην ανάπτυξη αξιόπιστων προγνωστικών μοντέλων όσο και στην εξασφάλιση της εξωτερικής τους επικύρωσης και της δυνατότητας εφαρμογής τους σε διαφορετικά κλινικά περιβάλλοντα.

Σε πρώτο στάδιο πραγματοποιήθηκε συστηματική αναζήτηση πραγματικών κλινικών δεδομένων σε δημόσια αποθετήρια και μέσω πιθανών συνεργασιών με φορείς υγείας. Διαπιστώθηκε ότι δεν υπάρχουν δημόσια διαθέσιμα σύνολα με επαρκείς, τυποποιημένες μεταβλητές και σαφώς ορισμένα καταληκτικά σημεία (π.χ. χρόνος πλήρους λειτουργικής αποκατάστασης), ενώ η πρόσβαση σε μη δημόσιες βάσεις ήταν περιορισμένη λόγω κανονιστικών (GDPR/HIPAA), ηθικών και οργανωτικών εμποδίων, καθώς και ετερογένειας πρωτοκόλλων καταγραφής. Ως εκ τούτου, υιοθετήθηκε τεκμηριωμένα η λύση των συνθετικών δεδομένων ως αναγκαίος συμβιβασμός, με ρητή αναγνώριση του περιορισμού και πρόβλεψη για μελλοντική εξωτερική επικύρωση σε πραγματικά κλινικά δεδομένα [3][21].

#### 3.3.1 Προβλήματα Έλλειψης Διαθέσιμων Δεδομένων

Η έλλειψη επαρκών και ποιοτικών δεδομένων αποτελεί ένα από τα σημαντικότερα εμπόδια για την πρόοδο της έρευνας και την εφαρμογή της μηχανικής μάθησης στην ιατρική και ειδικότερα στην

ορθοπεδική. Πολλές μελέτες επισημαίνουν ότι η πρόσβαση σε μεγάλα, ετερογενή και καλά τεκμηριωμένα σύνολα δεδομένων είναι συχνά περιορισμένη λόγω νομικών, ηθικών και τεχνικών παραγόντων [3]. Η προστασία των προσωπικών δεδομένων των ασθενών, όπως ορίζεται από κανονισμούς όπως ο GDPR και το HIPAA, περιορίζει τη διαμοίραση και τη διασύνδεση δεδομένων μεταξύ διαφορετικών φορέων και χωρών, καθιστώντας δύσκολη τη δημιουργία βάσεων πολλαπλών κέντρων μεγάλης κλίμακας.

Επιπλέον, η ετερογένεια στα πρωτόκολλα συλλογής και καταγραφής δεδομένων, η απουσία τυποποιημένων ορισμών για τις κλινικές εκβάσεις και η ύπαρξη ελλείπων ή ανακριβών εγγραφών οδηγούν σε προβλήματα ποιότητας και αξιοπιστίας των διαθέσιμων συνόλων [3]. Η περιορισμένη διαλειτουργικότητα μεταξύ διαφορετικών πληροφοριακών συστημάτων και η έλλειψη κοινών προτύπων δεδομένων καθιστούν πιο έντονο το πρόβλημα, δυσχεραίνοντας τη συνδυασμένη ανάλυση και τη γενίκευση των ευρημάτων.

Τέλος, σε περιπτώσεις σπάνιων παθήσεων ή ειδικών υποομάδων ασθενών, ο μικρός αριθμός περιστατικών καθιστά αδύνατη την ανάπτυξη αξιόπιστων αλγορίθμων μηχανικής μάθησης, ενώ η απώλεια ή η ελλιπής καταγραφή δεδομένων μπορεί να οδηγήσει σε μεροληψία και περιορισμένη εφαρμογή των μοντέλων στην κλινική πράξη [21]. Συνολικά, η έλλειψη διαθέσιμων δεδομένων αποτελεί σημαντικό εμπόδιο για την πρόοδο της βιοϊατρικής έρευνας και αναδεικνύει την ανάγκη για εναλλακτικές προσεγγίσεις, όπως η δημιουργία συνθετικών συνόλων δεδομένων.

### 3.3.2 Κίνητρο για Δημιουργία Συνθετικών Δεδομένων

Η δημιουργία συνθετικών συνόλων δεδομένων έχει κριθεί ως μια καινοτόμος και αποτελεσματική λύση για την αντιμετώπιση των περιορισμών που σχετίζονται με την έλλειψη πραγματικών κλινικών δεδομένων. Τα συνθετικά δεδομένα ορίζονται ως τεχνητά παραγόμενα δεδομένα που προσομοιάζουν τα στατιστικά χαρακτηριστικά και τις συσχετίσεις των πραγματικών συνόλων, χωρίς να περιέχουν πληροφορίες που να ταυτοποιούν συγκεκριμένους ασθενείς [3]. Η παραγωγή τους μπορεί να επιτευχθεί μέσω διαφόρων τεχνικών, όπως γενετικοί αλγόριθμοι (GANs), στατιστικά μοντέλα ή προσομοιώσεις βασισμένες σε πραγματικά δεδομένα.

Ένα από τα πιο βασικά πλεονεκτήματα των συνθετικών δεδομένων είναι η δυνατότητα ενίσχυσης του όγκου και της ποικιλίας των διαθέσιμων δεδομένων, γεγονός που διευκολύνει την εκπαίδευση και τη δοκιμή αλγορίθμων μηχανικής μάθησης, ιδιαίτερα σε περιπτώσεις σπάνιων παθήσεων ή πληθυσμών που δεν εκπροσωπούνται επαρκώς [3]. Επιπλέον, τα συνθετικά δεδομένα συμβάλλουν στην προστασία της ιδιωτικότητας των ασθενών, καθώς δεν περιέχουν ευαίσθητες προσωπικές πληροφορίες, επιτρέποντας έτσι την ευκολότερη διαμοίραση και συνεργασία μεταξύ ερευνητικών ομάδων και φορέων υγείας.

Η χρήση συνθετικών δεδομένων μπορεί επίσης να βοηθήσει στην αξιολόγηση της ανθεκτικότητας και της γενικευσιμότητας των αλγορίθμων, με σενάρια που δεν υπάρχουν στα πραγματικά δεδομένα και επιτρέποντας τη μελέτη της συμπεριφοράς των μοντέλων υπό διαφορετικές συνθήκες [21]. Ωστόσο, η αξιοπιστία και η χρησιμότητα των συνθετικών συνόλων εξαρτώνται σε μεγάλο βαθμό από την ποιότητα των μεθόδων παραγωγής και την πιστότητα με την οποία αναπαράγουν τις στατιστικές ιδιότητες των πραγματικών δεδομένων [3].

Συνολικά, το κίνητρο για τη δημιουργία συνθετικών δεδομένων στηρίζεται στην ανάγκη υπέρβασης των περιορισμών που επιβάλλει η έλλειψη πραγματικών δεδομένων, με στόχο την προώθηση της έρευνας, την ενίσχυση της καινοτομίας και τη διασφάλιση της προστασίας της ιδιωτικότητας στον τομέα της υγείας.

### 3.3.3 Περιορισμοί και Προκλήσεις των Συνθετικών Δεδομένων

Παρά τα σημαντικά πλεονεκτήματα που προσφέρουν τα συνθετικά δεδομένα στην έρευνα και την ανάπτυξη αλγορίθμων μηχανικής μάθησης, η χρήση τους συνοδεύεται από ορισμένους ουσιώδεις περιορισμούς και προκλήσεις. Ένα από τα βασικότερα ζητήματα αφορά την εγκυρότητα των συνθετικών δεδομένων ως προς την αναπαράσταση της πολυπλοκότητας, των αλληλεπιδράσεων και της ετερογένειας που χαρακτηρίζουν τα πραγματικά κλινικά δεδομένα[3]. Η αδυναμία πλήρους αποτύπωσης σπάνιων φαινομένων ή πολύπλοκων συσχετίσεων μπορεί να οδηγήσει σε μεροληψία ή σε υπεραπλουστευμένες αναπαραστάσεις, περιορίζοντας τη χρηστικότητα των συνθετικών συνόλων για την εκπαίδευση και την επικύρωση αλγορίθμων.

Επιπλέον, η αξιολόγηση της ποιότητας των συνθετικών δεδομένων αποτελεί μια ιδιαίτερα απαιτητική διαδικασία, καθώς κρίνεται αναγκαία η σύγκριση με πραγματικά δεδομένα και η χρήση εξειδικευμένων μετρικών για την εκτίμηση της στατιστικής ομοιότητας και της διατήρησης των κλινικά σημαντικών χαρακτηριστικών [21]. Η ανεπαρκής επικύρωση μπορεί να οδηγήσει στην ανάπτυξη μοντέλων που αποτυγχάνουν να γενικεύσουν σε πραγματικά κλινικά σενάρια ή που παρουσιάζουν μειωμένη αξιοπιστία κατά την εφαρμογή τους στην πράξη.

Επιπρόσθετα, η χρήση συνθετικών δεδομένων φέρνει στην επιφάνεια ηθικά και νομικά ζητήματα, όπως η διασφάλιση της μη αναγνωρισιμότητας των ασθενών, η ιδιοκτησία των παραγόμενων συνόλων και η διαφάνεια ως προς τη διαδικασία παραγωγής και χρήση τους. Η έλλειψη σαφών κατευθυντήριων γραμμών και προτύπων για τη δημιουργία και την αξιολόγηση συνθετικών δεδομένων εντείνει τις ανησυχίες σχετικά με την αξιοπιστία και την αποδοχή τους από την επιστημονική και ιατρική κοινότητα.

Συνολικά, αν και τα συνθετικά δεδομένα αποτελούν ένα πολλά υποσχόμενο εργαλείο για την προώθηση της έρευνας και της καινοτομίας, η αποτελεσματική και υπεύθυνη χρήση τους προϋποθέτει την αντιμετώπιση των παραπάνω προκλήσεων μέσω της ανάπτυξης αυστηρών μεθοδολογιών, της διαρκούς επικύρωσης και της διαφάνειας σε όλα τα στάδια της διαδικασίας.

### 3.3.4 Συμπεράσματα

Συνοψίζοντας, τα συνθετικά δεδομένα αναδεικνύονται ως ένα ιδιαίτερα χρήσιμο και καινοτόμο εργαλείο για την αντιμετώπιση των περιορισμών που επιβάλλει η έλλειψη πραγματικών κλινικών δεδομένων στην ιατρική έρευνα και ειδικότερα στην ανάπτυξη αλγορίθμων μηχανικής μάθησης. Η δυνατότητα δημιουργίας μεγάλων, ποικίλων και ασφαλών συνόλων δεδομένων συμβάλλει στην ενίσχυση της εκπαίδευσης και της επικύρωσης προγνωστικών μοντέλων, ενώ παράλληλα διασφαλίζει την προστασία της ιδιωτικότητας των ασθενών [3]. Παρά τα σημαντικά πλεονεκτήματα, η αξιοποίηση των συνθετικών δεδομένων προϋποθέτει την αντιμετώπιση προκλήσεων που σχετίζονται με την πιστότητα και την αξιοπιστία τους, καθώς και την ανάπτυξη αυστηρών μεθοδολογιών για την επικύρωση και τη διαφάνεια της διαδικασίας παραγωγής [3] [21].

Οι μελλοντικές προοπτικές περιλαμβάνουν τη βελτίωση των τεχνικών παραγωγής συνθετικών δεδομένων, την ενσωμάτωση πολυτροπικών και πολυεπίπεδων πληροφοριών, καθώς και τη δημιουργία διεθνών προτύπων και κατευθυντήριων γραμμών για τη χρήση τους στη βιοϊατρική έρευνα. Η διεπιστημονική συνεργασία μεταξύ επιστημόνων δεδομένων, κλινικών ιατρών και νομικών εμπειρογνομόνων θα αποτελέσει καθοριστικό παράγοντα για την υπεύθυνη και αποτελεσματική αξιοποίηση των συνθετικών δεδομένων, με τελικό στόχο τη βελτίωση της ποιότητας της έρευνας και της φροντίδας των ασθενών.

### 3.4 Σχετικές Μελέτες σε Άλλες Παθήσεις

Η πρόβλεψη της αποκατάστασης ασθενών μέσω αλγορίθμων μηχανικής μάθησης έχει απασχολήσει έντονα τη διεθνή βιβλιογραφία, όχι μόνο στον τομέα των καταγμάτων, αλλά και σε ένα ευρύ φάσμα άλλων ορθοπεδικών και νευρολογικών παθήσεων. Η ακριβής εκτίμηση της πορείας αποκατάστασης μετά από χειρουργικές επεμβάσεις ή τραυματισμούς, όπως η ρήξη πρόσθιου χιαστού συνδέσμου, τα κατάγματα ισχίου, οι παθήσεις της σπονδυλικής στήλης και οι νευρολογικές διαταραχές, αποτελεί κρίσιμο παράγοντα για την εξατομίκευση της θεραπείας και τη βελτιστοποίηση των κλινικών αποτελεσμάτων. Η αξιοποίηση αλγορίθμων μηχανικής μάθησης σε αυτά τα πεδία έχει επιτρέψει την ανάλυση μεγάλων και ετερογενών συνόλων δεδομένων, την αναγνώριση προγνωστικών παραγόντων και την ανάπτυξη εργαλείων υποστήριξης της κλινικής απόφασης. Στο παρόν υποκεφάλαιο παρουσιάζονται ενδεικτικές μελέτες που αφορούν την πρόβλεψη αποκατάστασης σε άλλες παθήσεις, με στόχο τη συγκριτική ανάλυση των εφαρμογών και των αποτελεσμάτων των σύγχρονων τεχνικών μηχανικής μάθησης σε διαφορετικά κλινικά πλαίσια.

#### 3.4.1 Μελέτες σε Αποκατάσταση Πρόσθιου Χιαστού Συνδέσμου

Η αποκατάσταση μετά από ρήξη ή χειρουργική αποκατάσταση του πρόσθιου χιαστού συνδέσμου (ACL) αποτελεί ένα από τα πλέον μελετημένα πεδία εφαρμογής τεχνικών μηχανικής μάθησης στην ορθοπεδική. Η πολυπλοκότητα της αποκατάστασης, η ποικιλομορφία των ασθενών και η ανάγκη για εξατομικευμένη πρόγνωση έχουν οδηγήσει στην ανάπτυξη και αξιολόγηση πληθώρας αλγορίθμων πρόβλεψης.

Σε πρόσφατη μελέτη, οι Martin et al. (2021) χρησιμοποίησαν αλγορίθμους μηχανικής μάθησης, όπως Random Forest και Gradient Boosting, για την πρόβλεψη του κινδύνου δεύτερης επέμβασης μετά από αποκατάσταση ACL. Τα μοντέλα εκπαιδεύτηκαν σε μεγάλο αριθμό κλινικών και λειτουργικών δεδομένων, επιτυγχάνοντας υψηλή ακρίβεια και αναδεικνύοντας σημαντικούς προγνωστικούς παράγοντες, όπως η ηλικία, το φύλο, ο τύπος μοσχεύματος και το ιστορικό τραυματισμών.

Αντίστοιχα, στη μελέτη των Ali et al. (2024), αναπτύχθηκε ένα υπολογιστικό σύστημα που συνδυάζει τεχνικές αναγνώρισης κίνησης, ανάλυσης στάσης σώματος και μηχανικής μάθησης (SVM, decision tree) για την υποστήριξη της αποκατάστασης αθλητών με ρήξη ACL. Το σύστημα αυτό επιτρέπει την αυτόματη αξιολόγηση της εκτέλεσης ασκήσεων αποκατάστασης μέσω βίντεο, παρέχοντας ανατροφοδότηση για τη σωστή τεχνική και την πρόληψη νέων τραυματισμών.

Επιπλέον, μελέτες όπως αυτή των Kim et al. (2021) και άλλων ερευνητικών ομάδων έχουν αξιοποιήσει δεδομένα από ηλεκτρονικούς ιατρικούς φακέλους, δημογραφικά και λειτουργικά χαρακτηριστικά, εφαρμόζοντας αλγορίθμους όπως Support Vector Machines, νευρωνικά δίκτυα και XGBoost για την πρόβλεψη της λειτουργικής αποκατάστασης και της επιστροφής στην αθλητική δραστηριότητα. Τα αποτελέσματα υπογραμμίζουν τη δυνατότητα των μοντέλων μηχανικής μάθησης να ενισχύσουν την κλινική απόφαση, αν και η γενικευσιμότητα και η ερμηνευσιμότητα των μοντέλων παραμένουν προκλήσεις για την ευρεία εφαρμογή τους στην καθημερινή πράξη.

#### 3.4.2 Μελέτες σε Αποκατάσταση Ισχίου

Η αποκατάσταση μετά από κάταγμα ή χειρουργική επέμβαση στο ισχίο αποτελεί ένα από τα σημαντικότερα πεδία εφαρμογής τεχνικών μηχανικής μάθησης στην ορθοπεδική, λόγω της υψηλής επίπτωσης, της πολυπλοκότητας της φροντίδας και της μεγάλης ετερογένειας του πληθυσμού των ασθενών. Η ακριβής πρόβλεψη της λειτουργικής αποκατάστασης, της θνητότητας και των επιπλοκών

μετά από κάταγμα ισχίου είναι ζωτικής σημασίας για τη βελτιστοποίηση της θεραπευτικής στρατηγικής και την κατανομή των υγειονομικών πόρων.

Σε πρόσφατη μελέτη, αναπτύχθηκε μοντέλο μηχανικής μάθησης για την προεγχειρητική πρόβλεψη της λειτουργικής αποκατάστασης ενός έτους μετά από χειρουργείο ισχίου σε ηλικιωμένους ασθενείς, αξιοποιώντας δημογραφικά, κλινικά και λειτουργικά δεδομένα [22]. Τα αποτελέσματα έδειξαν ότι αλγόριθμοι όπως τα Random Forests και τα νευρωνικά δίκτυα μπορούν να επιτύχουν υψηλή ακρίβεια πρόβλεψης, αναδεικνύοντας ως σημαντικούς προγνωστικούς παράγοντες την ηλικία, το επίπεδο λειτουργικότητας πριν τον τραυματισμό και τις συνοσηρότητες.

Παράλληλα, μελέτες που βασίστηκαν σε μεγάλες βάσεις δεδομένων, όπως το Swedish Fracture Register και το National Hip Fracture Database, έχουν αξιοποιήσει τεχνικές μηχανικής μάθησης για την πρόβλεψη της θνητότητας, της διάρκειας νοσηλείας και της πιθανότητας επανεισαγωγής μετά από κάταγμα ισχίου [18][12]. Η ανάλυση μεγάλου όγκου δεδομένων επέτρεψε την ταυτοποίηση παραγόντων κινδύνου και τη δημιουργία εργαλείων υποστήριξης της κλινικής απόφασης, αν και η ετερογένεια των δεδομένων και η ανάγκη για εξωτερική επικύρωση παραμένουν προκλήσεις.

Συνολικά, η εφαρμογή αλγορίθμων μηχανικής μάθησης στην αποκατάσταση του ισχίου προσφέρει σημαντικές δυνατότητες για την εξατομίκευση της φροντίδας και τη βελτίωση των κλινικών αποτελεσμάτων, ενώ παράλληλα αναδεικνύει την ανάγκη για περαιτέρω έρευνα σε πολυκεντρικά και ετερογενή δείγματα.

#### **3.4.3 Παραδείγματα από Άλλες Ορθοπεδικές Παθήσεις**

Η εφαρμογή τεχνικών μηχανικής μάθησης δεν περιορίζεται στην αποκατάσταση μετά από κατάγματα ή επεμβάσεις στο ισχίο και τον πρόσθιο χιαστό, αλλά έχει επεκταθεί και σε άλλες ορθοπεδικές παθήσεις, όπως η αρθροπλαστική γόνατος, οι κακώσεις της σπονδυλικής στήλης και τα κατάγματα του άνω άκρου. Σε αυτές τις περιπτώσεις, η πρόβλεψη της λειτουργικής αποκατάστασης, της διάρκειας νοσηλείας, της πιθανότητας επιπλοκών και της ανάγκης για επανεπέμβαση αποτελεί σημαντικό πεδίο έρευνας.

Ενδεικτικά, στη μελέτη των Karhade et al. (2019), αναπτύχθηκαν και επικυρώθηκαν αλγόριθμοι μηχανικής μάθησης για την πρόβλεψη της έκβασης μετά από χειρουργική αντιμετώπιση μεταστάσεων στη σπονδυλική στήλη. Τα μοντέλα, που βασίστηκαν σε δεδομένα από μεγάλες βάσεις, επέτρεψαν την ακριβή εκτίμηση της πιθανότητας εξιτηρίου σε δομές αποκατάστασης ή στο σπίτι, λαμβάνοντας υπόψη δημογραφικούς, κλινικούς και λειτουργικούς παράγοντες.

Επιπλέον, η εφαρμογή τεχνικών βαθιάς μάθησης (deep learning) σε δεδομένα ηλεκτρονικών ιατρικών φακέλων και απεικονιστικών εξετάσεων έχει επιτρέψει την αυτόματη διάγνωση και πρόγνωση σε πληθώρα ορθοπεδικών παθήσεων, βελτιώνοντας την ταχύτητα και την ακρίβεια της κλινικής απόφασης [12][14]. Παρά τα ενθαρρυντικά αποτελέσματα, η ετερογένεια των δεδομένων και η ανάγκη για εξωτερική επικύρωση παραμένουν προκλήσεις για τη γενικευσιμότητα των μοντέλων.

Συνολικά, η χρήση μηχανικής μάθησης σε διάφορες ορθοπεδικές παθήσεις αναδεικνύει τη δυναμική των σύγχρονων αλγορίθμων στην πρόβλεψη της αποκατάστασης και την υποστήριξη της κλινικής πρακτικής, ενώ παράλληλα υπογραμμίζει την ανάγκη για περαιτέρω έρευνα σε ετερογενή δείγματα.

### 3.4.4 Παραδείγματα από Νευρολογικές/Άλλες Παθήσεις

Η εφαρμογή τεχνικών μηχανικής μάθησης για την πρόβλεψη της αποκατάστασης δεν περιορίζεται στις ορθοπεδικές παθήσεις, αλλά έχει επεκταθεί σημαντικά και σε νευρολογικές και άλλες χρόνιες παθήσεις, όπου η πρόγνωση της λειτουργικής έκβασης αποτελεί κρίσιμο παράγοντα για τον σχεδιασμό της θεραπείας και τη διαχείριση των πόρων υγείας. Ενδεικτικά, στον τομέα της αποκατάστασης μετά από οξύ ισχαιμικό εγκεφαλικό επεισόδιο, μελέτες έχουν αξιοποιήσει αλγορίθμους όπως τα Random Forests, τα Support Vector Machines και τα νευρωνικά δίκτυα για την πρόβλεψη της λειτουργικής αποκατάστασης και της επιβίωσης, λαμβάνοντας υπόψη κλινικά, απεικονιστικά και δημογραφικά δεδομένα [13][16]. Τα μοντέλα αυτά έχουν επιτύχει υψηλή ακρίβεια πρόβλεψης, συχνά υπερβαίνοντας τα παραδοσιακά κλινικά scores, και έχουν συμβάλει στην έγκαιρη αναγνώριση ασθενών υψηλού κινδύνου για φτωχή αποκατάσταση.

Παράλληλα, στη νευροχειρουργική, η χρήση μηχανικής μάθησης έχει επιτρέψει την πρόβλεψη της έκβασης μετά από τραυματισμούς του κεντρικού νευρικού συστήματος, εγκεφαλικές κακώσεις και χειρουργικές επεμβάσεις, διευκολύνοντας τη λήψη αποφάσεων και την εξατομίκευση της φροντίδας [17]. Επιπλέον, η ανάλυση δεδομένων ηλεκτρονικών ιατρικών φακέλων με τεχνικές βαθιάς μάθησης έχει βελτιώσει την πρόβλεψη της αποκατάστασης και της επιβίωσης σε πληθώρα χρόνιων παθήσεων, όπως καρδιαγγειακά νοσήματα και διαβήτη, ενισχύοντας τη δυνατότητα έγκαιρης παρέμβασης και βελτίωσης των κλινικών αποτελεσμάτων [14].

Συγκριτικά με τις ορθοπεδικές παθήσεις, οι μελέτες σε νευρολογικά και άλλα χρόνια νοσήματα αναδεικνύουν παρόμοιες προκλήσεις, όπως η ετερογένεια των δεδομένων, η ανάγκη για μεγάλα και ποιοτικά δείγματα, καθώς και η προσπάθεια ερμηνείας των αλγορίθμων. Ωστόσο, η πολυπλοκότητα των δεδομένων και η ανάγκη για πολυπαραγοντική ανάλυση συχνά απαιτούν τη χρήση πιο σύνθετων αλγορίθμων, όπως τα βαθιά νευρωνικά δίκτυα, για την επίτευξη αξιόπιστων και γενικεύσιμων προβλέψεων [14][13].

Συνολικά, η εφαρμογή της μηχανικής μάθησης σε νευρολογικές και άλλες παθήσεις διευρύνει τις δυνατότητες της εξατομικευμένης ιατρικής και αναδεικνύει τη σημασία της διεπιστημονικής προσέγγισης για τη βελτίωση της αποκατάστασης και της ποιότητας ζωής των ασθενών.

### 3.4.5 Συμπεράσματα

Συνοψίζοντας, η εφαρμογή τεχνικών μηχανικής μάθησης στην πρόβλεψη της αποκατάστασης έχει επιφέρει σημαντικές εξελίξεις τόσο στις ορθοπεδικές όσο και στις νευρολογικές παθήσεις. Τα μοντέλα μηχανικής μάθησης, όπως τα Random Forests, τα Support Vector Machines και τα βαθιά νευρωνικά δίκτυα, έχουν αποδείξει τη δυνατότητά τους να εντοπίζουν προγνωστικούς παράγοντες και να παρέχουν ακριβείς προβλέψεις για την έκβαση της αποκατάστασης σε ένα ευρύ φάσμα κλινικών καταστάσεων [23][13][24]. Η ανάλυση μεγάλων και ετερογενών συνόλων δεδομένων έχει ενισχύσει την εξατομίκευση της φροντίδας και τη λήψη τεκμηριωμένων κλινικών αποφάσεων, ενώ η ενσωμάτωση πολυπαραγοντικών πληροφοριών έχει βελτιώσει τη γενικευσιμότητα των μοντέλων [12][13].

Ωστόσο, κοινές προκλήσεις παραμένουν η ετερογένεια των δεδομένων, η ανάγκη για εξωτερική επικύρωση και η ερμηνευσιμότητα των αλγορίθμων, τόσο στις ορθοπεδικές όσο και στις νευρολογικές παθήσεις [17][3]. Επιπλέον, η πολυπλοκότητα των κλινικών παραμέτρων και η διαρκής εξέλιξη των θεραπευτικών πρακτικών απαιτούν τη συνεχή προσαρμογή και επικαιροποίηση των προγνωστικών εργαλείων. Η διεπιστημονική συνεργασία, η ανάπτυξη ανοιχτών και διαλειτουργικών βάσεων δεδομένων, καθώς και η ενσωμάτωση σύγχρονων τεχνικών τεχνητής νοημοσύνης, αναμένεται να

ενισχύσουν περαιτέρω τη συμβολή της μηχανικής μάθησης στη βελτίωση της αποκατάστασης και της ποιότητας ζωής των ασθενών.

### 3.5 Επίλογος

Το παρόν κεφάλαιο παρουσίασε τη σημασία της διαθεσιμότητας και της ποιότητας των δεδομένων για την πρόοδο της έρευνας στην πρόβλεψη της αποκατάστασης, τόσο στα κατάγματα όσο και σε άλλες ορθοπαιδικές και νευρολογικές παθήσεις. Η ανάλυση των βάσεων δεδομένων που ήδη υπάρχουν και των σχετικών μελετών κατέδειξε ότι η αξιοποίηση μεγάλων, πολυκεντρικών (multicenter) και ετερογενών συνόλων δεδομένων αποτελεί προϋπόθεση για την ανάπτυξη αξιόπιστων και γενικεύσιμων αλγορίθμων μηχανικής μάθησης [18][12]. Παράλληλα, η έλλειψη επαρκών πραγματικών δεδομένων και οι περιορισμοί που απορρέουν από νομικά, ηθικά και τεχνικά εμπόδια, καθιστούν αναγκαία τη διερεύνηση εναλλακτικών λύσεων, όπως η δημιουργία συνθετικών συνόλων δεδομένων [3].

Οι μελέτες που εμβαθύνουν στη σύγκριση μεταξύ διαφορετικών παθήσεων ανέδειξε τη δυναμική των τεχνικών μηχανικής μάθησης στην πρόβλεψη της αποκατάστασης, αλλά και τις κοινές προκλήσεις που αφορούν την ετερογένεια των δεδομένων, την ανάγκη για εξωτερική επικύρωση και την ερμηνευσιμότητα των αλγορίθμων [23][13][14]. Η διεπιστημονική συνεργασία, η ανάπτυξη διαλειτουργικών και ανοιχτών βάσεων δεδομένων, καθώς και η ενσωμάτωση σύγχρονων τεχνικών τεχνητής νοημοσύνης, αποτελούν βασικές προϋποθέσεις για τη βελτίωση της ακρίβειας, της αξιοπιστίας και της ευκολίας στη χρήση των προγνωστικών εργαλείων στη σύγχρονη ιατρική πρακτική.

Συνολικά, το κεφάλαιο αυτό υπογραμμίζει ότι η πρόοδος στην πρόβλεψη της αποκατάστασης εξαρτάται από τη διαρκή βελτίωση της ποιότητας των δεδομένων, την υπεύθυνη χρήση συνθετικών συνόλων και την προώθηση της διαφάνειας και της ερμηνείας των αλγορίθμων, με τελικό στόχο τη βελτίωση της φροντίδας και της ποιότητας ζωής των ασθενών.

## Κεφάλαιο 4ο: Δημιουργία Συνθετικού Dataset

Η μελέτη της αποκατάστασης μετά από κατάγματα της περιφερικής κερκίδας (distal radius fractures) αποτελεί ένα από τα πλέον σημαντικά πεδία έρευνας στην ορθοπεδική και τη φυσικοθεραπεία, δεδομένης της υψηλής συχνότητας εμφάνισης των καταγμάτων αυτών, ιδιαίτερα σε ηλικιωμένους ασθενείς και άτομα με οστεοπόρωση [25]. Τα κατάγματα της περιφερικής κερκίδας, γνωστά και ως κατάγματα Colles, συνδέονται με σημαντική λειτουργική επιβάρυνση, περιορισμό της κινητικότητας του άνω άκρου, μείωση της ποιότητας ζωής και αυξημένο κίνδυνο μελλοντικών πτώσεων και καταγμάτων [26].

Η έγκαιρη και κατάλληλη αποκατάσταση μετά από χειρουργική ή συντηρητική αντιμετώπιση των καταγμάτων αυτών έχει αποδειχθεί ότι συμβάλλει καθοριστικά στη βελτίωση της λειτουργικότητας του καρπού και του άνω άκρου, στη μείωση του πόνου και στην ταχύτερη επάνοδο στις καθημερινές δραστηριότητες [27]. Σύγχρονες μετα-αναλύσεις και συστηματικές ανασκοπήσεις τεκμηριώνουν ότι η έναρξη της φυσικοθεραπευτικής παρέμβασης σε πρώιμο στάδιο μετά τη σταθεροποίηση του κατάγματος οδηγεί σε καλύτερα λειτουργικά αποτελέσματα, χωρίς να αυξάνει τον κίνδυνο επιπλοκών.

Η αξιολόγηση της λειτουργικής αποκατάστασης βασίζεται σε έγκυρα και αξιόπιστα εργαλεία, όπως η Κλίμακα Φυσικής Δραστηριότητας για Ηλικιωμένους [28]. Παράλληλα, η χρήση συνθετικών δεδομένων και προηγμένων στατιστικών μεθόδων επιτρέπει την ασφαλή και αξιόπιστη ανάλυση μεγάλων πληθυσμών ασθενών, διασφαλίζοντας την προστασία των προσωπικών δεδομένων και την αναπαραγωγιμότητα των ερευνητικών αποτελεσμάτων [29][3].

Η παρούσα εργασία αξιοποιεί τη σύγχρονη βιβλιογραφία και τεκμηριωμένες μεθοδολογίες για τη δημιουργία και ανάλυση δεδομένων που αφορούν την αποκατάσταση μετά από κατάγματα της περιφερικής κερκίδας. Μέσω της ενσωμάτωσης κλινικών, λειτουργικών και δημογραφικών παραμέτρων, επιχειρείται η ολιστική προσέγγιση της αποκατάστασης, με στόχο τη βελτιστοποίηση των θεραπευτικών πρωτοκόλλων και την εξατομίκευση της φροντίδας των ασθενών.

Συνοψίζοντας, η μελέτη της αποκατάστασης μετά από κατάγματα της περιφερικής κερκίδας αποτελεί ένα πολυπαραγοντικό πεδίο, όπου η διεπιστημονική συνεργασία, η αξιοποίηση της τεχνολογίας και η τεκμηριωμένη κλινική πρακτική συνδυάζονται για τη βελτίωση της λειτουργικότητας και της ποιότητας ζωής των ασθενών. Η παρούσα εργασία φιλοδοξεί να συμβάλει στην περαιτέρω κατανόηση και βελτίωση των θεραπευτικών παρεμβάσεων, αξιοποιώντας τόσο τη διεθνή βιβλιογραφία όσο και σύγχρονες μεθόδους ανάλυσης δεδομένων.

### 4.1 Επιλογή Παθολογίας

Η επιλογή του περιφερικού κατάγματος της κερκίδας ως αντικείμενο της παρούσας μελέτης βασίζεται στη μεγάλη επιδημιολογική και κλινική του σημασία. Τα κατάγματα της περιφερικής κερκίδας αποτελούν το συχνότερο κάταγμα του άνω άκρου στους ενήλικες, με ιδιαίτερα υψηλή επίπτωση σε ηλικιωμένες γυναίκες, κυρίως λόγω της αυξημένης συχνότητας της οστεοπόρωσης σε αυτή την πληθυσμιακή ομάδα [30][25]. Η κλινική εικόνα των καταγμάτων αυτών χαρακτηρίζεται από πόνο, παραμόρφωση, απώλεια λειτουργικότητας και συχνά σημαντικό περιορισμό της αυτονομίας, ειδικά σε άτομα τρίτης ηλικίας.

Η επιλογή της συγκεκριμένης παθολογίας για τη δημιουργία συνθετικού συνόλου δεδομένων δικαιολογείται από πολλαπλούς λόγους. Πρώτον, η υψηλή συχνότητα εμφάνισης και η μεγάλη

ετερογένεια ως προς τα κλινικά χαρακτηριστικά και τις θεραπευτικές προσεγγίσεις καθιστούν το κατάγμα της κερκίδας ιδανικό πεδίο για την ανάπτυξη και αξιολόγηση προγνωστικών μοντέλων. Δεύτερον, η έκβαση της αποκατάστασης εξαρτάται από ένα ευρύ φάσμα παραγόντων – δημογραφικών, κλινικών, λειτουργικών και κοινωνικών – γεγονός που επιτρέπει τη μελέτη της αλληλεπίδρασης πολλών μεταβλητών σε ένα ρεαλιστικό πλαίσιο [31][32].

Επιπλέον, η ύπαρξη πλούσιας διεθνούς βιβλιογραφίας και τεκμηριωμένων εργαλείων αξιολόγησης της λειτουργικότητας και της ποιότητας ζωής μετά από κατάγμα κερκίδας διευκολύνει τη δημιουργία ενός συνθετικού συνόλου δεδομένων που να αντανακλά τις πραγματικές κλινικές συνθήκες [33][26]. Τέλος, η επιλογή αυτή επιτρέπει τη γενίκευση των ευρημάτων και τη μελλοντική εφαρμογή των μεθοδολογιών σε άλλα συχνά ορθοπεδικά κατάγματα.


Συνολικά, το περιφερικό κατάγμα της κερκίδας αποτελεί μια παθολογία με υψηλό κλινικό και ερευνητικό ενδιαφέρον, προσφέροντας το κατάλληλο υπόβαθρο για τη μελέτη της αποκατάστασης μέσω της χρήσης συνθετικών δεδομένων και σύγχρονων αναλυτικών μεθόδων.

## 4.2 Επιλογή και Περιγραφή Μεταβλητών

Η επιλογή των μεταβλητών που συμπεριλήφθηκαν στο συνθετικό σύνολο δεδομένων βασίστηκε σε συστηματική ανασκόπηση της διεθνούς βιβλιογραφίας, σε συνδυασμό με κλινική εμπειρία και τεκμηριωμένη γνώση των παραγόντων που επηρεάζουν την πρόγνωση και την αποκατάσταση μετά από περιφερικό κατάγμα κερκίδας [30][3]. Η αναλυτική καταγραφή και τεκμηρίωση των μεταβλητών διασφαλίζει την εγκυρότητα και τη ρεαλιστικότητα του συνόλου δεδομένων, επιτρέποντας την ανάπτυξη αξιόπιστων προγνωστικών μοντέλων που αντανακλούν τις πραγματικές κλινικές συσχετίσεις.

### 4.2.1 Δημογραφικές μεταβλητές

Ηλικία (age): Η ηλικία αποτελεί έναν από τους σημαντικότερους προγνωστικούς παράγοντες για την αποκατάσταση μετά από κατάγμα της περιφερικής κερκίδας. Η αυξημένη ηλικία σχετίζεται με μεγαλύτερη συχνότητα οστεοπόρωσης, βραδύτερη αποκατάσταση και αυξημένο κίνδυνο επιπλοκών. Στο συνθετικό σύνολο δεδομένων, η ηλικία προσομοιώνεται με κατανομή που αντανακλά τη διπλή επιδημιολογική κορυφή (νεαροί ενήλικες και ηλικιωμένοι), διασφαλίζοντας ρεαλιστική αναπαράσταση του πληθυσμού-στόχου [30].



Σχήμα 4.1: Κατανομή Ηλικίας Ασθενών

Το σχήμα 4.1 απεικονίζει την κατανομή της ηλικίας στο συνθετικό σύνολο. Η μορφή είναι δι-κορυφική (bimodal), με αυξημένες συχνότητες στις ζώνες 20–30 και 80–90 ετών, αντανακλώντας δύο επιδημιολογικές ομάδες: νεαρούς ενήλικες με τραυματικού τύπου κατάγματα και ηλικιωμένους με οστεοπορωτικά κατάγματα. Η περιορισμένη παρουσία μεσαίων ηλικιών και η εντονότερη συγκέντρωση

στις προαναφερθείσες ζώνες είναι συμβατές με τη βιβλιογραφία και χρησιμοποιήθηκαν για τη ρεαλιστική βαθμονόμηση του συνθετικού dataset.

**Φύλο (sex):** Η συχνότητα των καταγμάτων κερκίδας είναι σημαντικά υψηλότερη στις γυναίκες, ιδίως μετά την εμμηνόπαυση, λόγω της προοδευτικής μείωσης της οστικής πυκνότητας [30][25]. Η μεταβλητή καταγράφεται ως «Ανδρας»/«Γυναίκα» και χρησιμοποιείται τόσο ως ανεξάρτητος προγνωστικός παράγοντας όσο και στη σύνθεση σύνθετων δεικτών κινδύνου (risk\_triad).

**Κυρίαρχο/Τραυματισμένο Άνω Άκρο (dominant\_hand\_injured):** Η διχοτόμηση «Ναι»/«Όχι» αποτυπώνει τη λειτουργική σημασία του τραυματισμού στο κυρίαρχο άκρο, καθώς σχετίζεται με μεγαλύτερη λειτουργική επιβάρυνση και δυσκολίες στην καθημερινή δραστηριότητα [3]. Η μεταβλητή αυτή εισάγεται ως πρώιμη πληροφορία διαθέσιμη αμέσως μετά τη διάγνωση.

#### 4.2.2 Κλινικές μεταβλητές

**Οστεοπόρωση (osteoporosis):** Καταγράφεται ως «Ναι»/«Όχι» βάσει ιστορικού ή μέτρησης οστικής πυκνότητας (DEXA). Η οστεοπόρωση αποτελεί θεμελιώδη παράγοντα κινδύνου τόσο για την εμφάνιση όσο και για την καθυστέρηση της ίασης του κατάγματος [25].

**Charlson Comorbidity Index (CCI):** Αριθμητικός δείκτης παράλληλων παθήσεων (εύρος 0–30), ο οποίος αντικατοπτρίζει τη βαρύτητα των παράλληλων παθήσεων και έχει αποδειχθεί ότι επηρεάζει τη διάρκεια και την έκβαση της αποκατάστασης [3].

**Edmonton Frail Scale:** Κλίμακα ευπάθειας (0–17) που αποτυπώνει τη συνολική φυσική και γνωστική κατάσταση του ασθενούς. Υψηλότερες τιμές συσχετίζονται με αυξημένο κίνδυνο επιπλοκών και δυσμενών εκβάσεων [3].

**Τριάδα Κινδύνου (risk\_triad):** Δυαδική μεταβλητή που συνδυάζει φύλο, ηλικία ( $\geq 65$  έτη) και οστεοπόρωση, εντοπίζοντας υποομάδες ασθενών με ιδιαίτερα αυξημένο κίνδυνο δυσμενών εκβάσεων [30].

**Κοινωνική/Οικογενειακή Υποστήριξη (social\_support):** Καταγράφεται ως τριών επιπέδων μεταβλητή (0=καμία, 1=μερική, 2=σταθερή). Η παρουσία κοινωνικής και ψυχολογικής υποστήριξης έχει συσχετιστεί με βελτιωμένη συμμόρφωση, ταχύτερη λειτουργική αποκατάσταση και χαμηλότερη ψυχολογική επιβάρυνση μετά από κατάγματα σε ηλικιωμένους (βλ. σχετική βιβλιογραφία).

**Τύπος κατάγματος (fracture\_type):** Καταγράφεται ως 0=εξωαρθρικό, 1=ενδοαρθρικό. Τα ενδοαρθρικά κατάγματα σχετίζονται με αυξημένο χρόνο αποκατάστασης και συχνότερες επιπλοκές.

**Παρακτόπιση κατάγματος (displacement):** Καταγράφεται ως 0=όχι, 1=ναι. Η παρουσία παρακτόπισης σχετίζεται με μεγαλύτερη βαρύτητα κάκωσης και συχνά απαιτεί πιο επιθετική θεραπεία.

**Σταθερότητα κατάγματος (fracture\_stability):** Καταγράφεται ως 0=σταθερό, 1=ασταθές. Τα ασταθή κατάγματα έχουν μεγαλύτερη πιθανότητα παρακτόπισης και παρατεταμένη αποκατάσταση.

**Χειρουργική αντιμετώπιση (operative\_treatment):** Καταγράφεται ως 0=όχι, 1=ναι. Η χειρουργική αντιμετώπιση σχετίζεται με πιο σύνθετα κατάγματα και επηρεάζει τον χρόνο αποκατάστασης.

#### 4.2.3 Λειτουργικές μεταβλητές

**PASE Score:** Αριθμητική τιμή (0–400) που αποτυπώνει το επίπεδο φυσικής δραστηριότητας σε ηλικιωμένους. Η κλίμακα αυτή έχει συσχετιστεί με το λειτουργικό επίπεδο και τον ρυθμό ανάρρωσης μετά από ορθοπεδικά τραύματα [3].

#### 4.2.4 Σύνθετες μεταβλητές

Εκτιμώμενη Διάρκεια Ακινητοποίησης (`immobilization_days`): Αριθμός ημερών ακινητοποίησης (10–60), όπως εκτιμάται από τον θεράποντα ιατρό κατά την έξοδο από το νοσοκομείο. Η μεταβλητή αυτή λειτουργεί ως πρώιμος δείκτης επιβάρυνσης και επηρεάζει άμεσα τον συνολικό χρόνο αποκατάστασης [27].

Χρόνος αποκατάστασης σε εβδομάδες (`recovery_time_weeks`): Κύρια έκβαση του συνόλου δεδομένων, που προσομοιώνει το συνολικό διάστημα μέχρι την επίτευξη λειτουργικής αποκατάστασης. Υπολογίζεται ως συνάρτηση όλων των παραπάνω μεταβλητών, με κλινικά τεκμηριωμένα βάρη και προσθήκη τυχαίου θορύβου, ώστε να αντικατοπτρίζει τη ρεαλιστική, πολυπαραγοντική φύση της αποκατάστασης [3].

### 4.3 Διαδικασία Δημιουργίας Συνθετικών Δεδομένων

Η δημιουργία του συνθετικού συνόλου δεδομένων πραγματοποιήθηκε με τη χρήση προγραμματιστικών εργαλείων της Python (NumPy, Pandas), ακολουθώντας μια συστηματική διαδικασία που βασίστηκε σε βιβλιογραφικά δεδομένα, κλινικούς κανόνες και στατιστικές αρχές [3]. Η διαδικασία αυτή αποσκοπεί στην προσομοίωση ενός ρεαλιστικού πληθυσμού ασθενών με περιφερικό κάταγμα κερκίδας, διατηρώντας τις βασικές επιδημιολογικές και κλινικές συσχετίσεις που παρατηρούνται στην πραγματική κλινική πράξη [30].

Αρχικά, καθορίστηκε το μέγεθος του συνόλου δεδομένων, ώστε να διασφαλίζεται επαρκής στατιστική ισχύς και αντιπροσωπευτικότητα. Για κάθε μεταβλητή επιλέχθηκε κατάλληλη μέθοδος προσομοίωσης, λαμβάνοντας υπόψη τόσο τις κατανομές που περιγράφονται στη βιβλιογραφία όσο και τις κλινικές συσχετίσεις μεταξύ των παραγόντων. Για παράδειγμα, η ηλικία προσομοιώθηκε με κανονική κατανομή (μέση τιμή 68, τυπική απόκλιση 12), ώστε να αντικατοπτρίζει τη μεγαλύτερη συχνότητα εμφάνισης καταγμάτων σε ηλικιωμένους, ενώ το φύλο κατανέμεται με βάση τα επιδημιολογικά δεδομένα (περίπου 70% γυναίκες) [30].

Η παρουσία οστεοπόρωσης και παράλληλων παθήσεων (Charlson Index) αποδόθηκε με αυξημένη πιθανότητα σε γυναίκες άνω των 60 ετών, σύμφωνα με τα διεθνή δεδομένα [25]. Επιπλέον, εφαρμόστηκαν κανόνες και συσχετίσεις μεταξύ μεταβλητών, ώστε το σύνολο δεδομένων να αντανακλά ρεαλιστικές κλινικές καταστάσεις. Για παράδειγμα, οι ασθενείς με υψηλότερο δείκτη ευπάθειας (Edmonton Frail Scale) και άλλες παθήσεις εμφανίζουν μεγαλύτερο χρόνο αποκατάστασης, ενώ η έγκαιρη φυσικοθεραπεία και η αυξημένη φυσική δραστηριότητα σχετίζονται με ταχύτερη λειτουργική αποκατάσταση [27].

Το Σχήμα 4.2 παρουσιάζει ενδεικτικό κώδικα για τη σύνθεση βασικών μεταβλητών του συνθετικού συνόλου δεδομένων. Η ηλικία δειγματοληπτείται από κανονική κατανομή και περιορίζεται σε κλινικά ρεαλιστικό εύρος (`clipping`). Το φύλο ανατίθεται με προκαθορισμένες πιθανότητες, ενώ η οστεοπόρωση ορίζεται ως συνάρτηση ηλικίας και φύλου με στοχαστικό όρο, ώστε να αναπαράγονται γνωστά επιδημιολογικά μοτίβα. Η διαφάνεια των παραδοχών και οι έλεγχοι ρεαλιστικότητας τεκμηριώνουν τη διαδικασία σύνθεσης.

Η τελική δομή του συνόλου δεδομένων περιλαμβάνει όλες τις επιλεγμένες μεταβλητές, ενώ πραγματοποιήθηκε έλεγχος για την αποφυγή μη ρεαλιστικών τιμών και την τήρηση των βασικών κλινικών συσχετίσεων. Η διαδικασία αυτή διασφαλίζει ότι το συνθετικό σύνολο δεδομένων μπορεί να χρησιμοποιηθεί με αξιοπιστία για την ανάπτυξη και αξιολόγηση προγνωστικών μοντέλων, χωρίς να τίθενται σε κίνδυνο προσωπικά δεδομένα ασθενών [3].

```

import numpy as np
import pandas as pd

N = 1000 # μέγεθος δείγματος

# Ηλικία: κανονική κατανομή με μέση τιμή 68 και τυπική απόκλιση 12
age = np.random.normal(loc=68, scale=12, size=N).astype(int)
age = np.clip(age, 40, 95)

# Φύλο: 70% γυναίκες
sex = np.random.choice(['Γυναίκα', 'Ανδρας'], size=N, p=[0.7, 0.3])

# Οστεοπόρωση: 60% στις γυναίκες >60, 20% στους υπόλοιπους
osteoporosis = [
    1 if (s == 'Γυναίκα' and a > 65 and np.random.rand() < 0.6) or
    (np.random.rand() < 0.2)
    else 0
    for s, a in zip(sex, age)]

```

Σχήμα 4.2: Ενδεικτικός κώδικας σύνθεσης μεταβλητών (ηλικία, φύλο, οστεοπόρωση) για το συνθετικό dataset, με κατανομές, περιορισμούς τιμών και κανόνες βασισμένους στη βιβλιογραφία.

#### 4.4 Στατιστική Ανάλυση και Έλεγχος Συνέπειας

Η στατιστική ανάλυση του συνθετικού συνόλου δεδομένων αποτελεί κρίσιμο στάδιο για την αξιολόγηση της ποιότητας και της ρεαλιστικότητάς του, καθώς και για τη διασφάλιση ότι οι παραγόμενες κατανομές και οι συσχετίσεις μεταξύ των μεταβλητών αντανακλούν τις πραγματικές κλινικές συνθήκες [3]. Αρχικά, πραγματοποιήθηκε περιγραφική ανάλυση των βασικών δημογραφικών, κλινικών και λειτουργικών χαρακτηριστικών του πληθυσμού, με υπολογισμό μέσων όρων, τυπικών αποκλίσεων, ποσοστών και διαμέσων για κάθε μεταβλητή.

Για παράδειγμα, η μέση ηλικία του συνθετικού πληθυσμού κυμάνθηκε στα αναμενόμενα επίπεδα (π.χ. 68 έτη,  $SD=12$ ), με το ποσοστό των γυναικών να ανέρχεται στο 70%, όπως περιγράφεται στη διεθνή βιβλιογραφία για τα κατάγματα της περιφερικής κερκίδας [30]. Το ποσοστό οστεοπόρωσης στις γυναίκες άνω των 60 ετών προσεγγίζει το 60%, ενώ στους υπόλοιπους ασθενείς κυμαίνεται γύρω στο 20%, επιβεβαιώνοντας τη ρεαλιστικότητα της προσομοίωσης [25].

Αντίστοιχα, οι τιμές του Charlson Comorbidity Index και του Edmonton Frail Scale κατανέμονται σύμφωνα με τα επιδημιολογικά δεδομένα [32][28]. Η ανάλυση των συσχετίσεων μεταξύ των μεταβλητών ανέδειξε τις αναμενόμενες σχέσεις, όπως η συσχέτιση υψηλότερης ηλικίας και οστεοπόρωσης με αυξημένο χρόνο αποκατάστασης, καθώς και η θετική επίδραση της έγκαιρης φυσικοθεραπείας και της αυξημένης φυσικής δραστηριότητας στη λειτουργική αποκατάσταση [27].

Η συνέπεια του συνόλου δεδομένων ελέγχθηκε περαιτέρω μέσω συγκριτικής ανάλυσης με δημοσιευμένα επιδημιολογικά δεδομένα και με τη χρήση γραφημάτων (ιστογράμματα, boxplots, διαγράμματα συσχέτισης), τα οποία επιβεβαίωσαν την ομοιότητα των κατανομών και των συσχετίσεων με πραγματικούς πληθυσμούς ασθενών. Επιπλέον, πραγματοποιήθηκαν έλεγχοι για την αποφυγή

ακραίων ή μη ρεαλιστικών τιμών, καθώς και για τη διατήρηση της ετερογένειας που χαρακτηρίζει την κλινική πράξη.

Συνολικά, η στατιστική ανάλυση και ο έλεγχος συνέπειας τεκμηριώνουν ότι το συνθετικό σύνολο δεδομένων ανταποκρίνεται στις απαιτήσεις της κλινικής ρεαλιστικότητας και μπορεί να χρησιμοποιηθεί με ασφάλεια για την ανάπτυξη και αξιολόγηση προγνωστικών μοντέλων στον τομέα της αποκατάστασης μετά από κάταγμα της περιφερικής κερκίδας.

### 4.5 Ηθικά Ζητήματα Συνθετικών Δεδομένων

Η χρήση συνθετικών δεδομένων στην ιατρική έρευνα και την ανάπτυξη αλγορίθμων μηχανικής μάθησης εγείρει σημαντικά ηθικά ζητήματα, τα οποία σχετίζονται τόσο με την προστασία της ιδιωτικότητας όσο και με την αξιοπιστία και τη χρηστικότητα των παραγόμενων συνόλων δεδομένων[3]. Ένα από τα βασικά πλεονεκτήματα των συνθετικών δεδομένων είναι η δυνατότητα διαμοιρασμού και ανάλυσης μεγάλων πληθυσμών χωρίς να τίθεται σε κίνδυνο η ανωνυμία και η προστασία των προσωπικών δεδομένων των ασθενών. Αυτό διευκολύνει τη συνεργασία μεταξύ ερευνητικών ομάδων, την αναπαραγωγιμότητα των αποτελεσμάτων και την επιτάχυνση της επιστημονικής προόδου, χωρίς να απαιτείται η λήψη πολύπλοκων αδειών ή η συμμόρφωση με αυστηρά ρυθμιστικά πλαίσια [3].

Ωστόσο, η χρήση συνθετικών δεδομένων δεν στερείται περιορισμών και προκλήσεων. Παρά το γεγονός ότι τα δεδομένα αυτά δεν αντιστοιχούν σε πραγματικούς ασθενείς, η διαδικασία παραγωγής τους πρέπει να διασφαλίζει ότι δεν είναι δυνατή η αναγνώριση ή η ανακατασκευή ευαίσθητων πληροφοριών, ειδικά όταν χρησιμοποιούνται προηγμένες τεχνικές τεχνητής νοημοσύνης ή όταν το συνθετικό σύνολο δεδομένων βασίζεται σε μικρά ή εξειδικευμένα πραγματικά δείγματα. Επιπλέον, τα συνθετικά δεδομένα ενδέχεται να μην αποτυπώνουν πλήρως την πολυπλοκότητα και την ετερογένεια των πραγματικών κλινικών πληθυσμών, γεγονός που μπορεί να οδηγήσει σε μεροληψία ή σε υπεραπλουστευμένες αναπαραστάσεις [29].

Ηθικά ζητήματα προκύπτουν επίσης σε σχέση με τη διαφάνεια της διαδικασίας παραγωγής των συνθετικών δεδομένων, την ορθή ενημέρωση των χρηστών για τους περιορισμούς τους και την ανάγκη για σαφή διαχωρισμό μεταξύ συνθετικών και πραγματικών δεδομένων κατά τη δημοσίευση ερευνητικών αποτελεσμάτων. Η διεθνής βιβλιογραφία τονίζει τη σημασία της ανάπτυξης κατευθυντήριων γραμμών και προτύπων για τη δημιουργία, την αξιολόγηση και τη χρήση συνθετικών δεδομένων στην ιατρική έρευνα, με στόχο την προώθηση της ηθικής και υπεύθυνης καινοτομίας [3].

Συνοψίζοντας, τα συνθετικά δεδομένα προσφέρουν σημαντικές ευκαιρίες για την πρόοδο της ιατρικής έρευνας, υπό την προϋπόθεση ότι η χρήση τους διέπεται από αρχές διαφάνειας, υπευθυνότητας και σεβασμού της ιδιωτικότητας, ενώ παράλληλα λαμβάνονται υπόψη οι περιορισμοί και οι προκλήσεις που τα συνοδεύουν.

### 4.6 Επίλογος

Στο παρόν κεφάλαιο παρουσιάστηκε αναλυτικά η διαδικασία δημιουργίας ενός συνθετικού συνόλου δεδομένων για τη μελέτη της αποκατάστασης μετά από περιφερικό κάταγμα κερκίδας. Η επιλογή της συγκεκριμένης παθολογίας τεκμηριώθηκε βάσει της υψηλής επιδημιολογικής και κλινικής της σημασίας, καθώς και της δυνατότητας μελέτης πολυπαραγοντικών εκβάσεων που σχετίζονται με τη λειτουργικότητα και την ποιότητα ζωής των ασθενών. Η επιλογή και η περιγραφή των μεταβλητών βασίστηκαν στη διεθνή βιβλιογραφία και στην κλινική εμπειρία, διασφαλίζοντας ότι το σύνολο δεδομένων αντανακλά με ρεαλισμό τις πραγματικές κλινικές συνθήκες.

Η διαδικασία δημιουργίας των συνθετικών δεδομένων στηρίχθηκε σε τεκμηριωμένες στατιστικές μεθόδους και σε κανόνες που προκύπτουν από την κλινική πράξη, με στόχο την προσομοίωση ενός ετερογενούς και ρεαλιστικού πληθυσμού ασθενών. Η στατιστική ανάλυση και ο έλεγχος συνέπειας επιβεβαίωσαν ότι το σύνολο δεδομένων παρουσιάζει κατανομές και συσχετίσεις συμβατές με τα δημοσιευμένα επιδημιολογικά και κλινικά δεδομένα, ενισχύοντας την αξιοπιστία του ως εργαλείο για την ανάπτυξη και αξιολόγηση προγνωστικών μοντέλων.

Τέλος, αναδείχθηκαν τα ηθικά πλεονεκτήματα της χρήσης συνθετικών δεδομένων, όπως η προστασία της ιδιωτικότητας και η διευκόλυνση της επιστημονικής συνεργασίας, αλλά και οι περιορισμοί που σχετίζονται με την πιθανή απώλεια πολυπλοκότητας και την ανάγκη για διαφάνεια και υπεύθυνη χρήση. Συνολικά, η δημιουργία και η ανάλυση συνθετικών δεδομένων συνιστούν μια καινοτόμο και ασφαλή προσέγγιση για την προώθηση της έρευνας στην αποκατάσταση ορθοπεδικών παθήσεων, προσφέροντας νέες δυνατότητες για την εξατομίκευση της φροντίδας και τη βελτίωση των κλινικών εκβάσεων.

## Κεφάλαιο 5ο: Ανάπτυξη και Εκπαίδευση Μοντέλου

Η ραγδαία εξέλιξη της τεχνητής νοημοσύνης (AI) και της μηχανικής μάθησης (machine learning) τα τελευταία χρόνια έχει επιφέρει σημαντικές αλλαγές σε ένα ευρύ φάσμα επιστημονικών και τεχνολογικών πεδίων. Ιδιαίτερα, η ανάπτυξη και εφαρμογή αλγορίθμων βαθιάς μάθησης (deep learning) και μεθόδων ensemble, όπως τα τυχαία δάση (Random Forests), έχουν αναδείξει νέες δυνατότητες στην ανάλυση δεδομένων, την πρόβλεψη και τη λήψη αποφάσεων [8].

Η βαθιά μάθηση, ως υποπεδίο της μηχανικής μάθησης, βασίζεται στη χρήση τεχνητών νευρωνικών δικτύων με πολλαπλά επίπεδα (deep neural networks), τα οποία έχουν αποδειχθεί εξαιρετικά αποτελεσματικά σε πολύπλοκα προβλήματα, όπως η αναγνώριση εικόνας, η επεξεργασία φυσικής γλώσσας και η βιοϊατρική ανάλυση. Η ικανότητα των αλγορίθμων αυτών να μαθαίνουν αναπαραστάσεις υψηλού επιπέδου απευθείας από τα δεδομένα, χωρίς την ανάγκη χειροκίνητης εξαγωγής χαρακτηριστικών, έχει οδηγήσει σε σημαντικές βελτιώσεις της απόδοσης σε πολλές εφαρμογές [9].

Παράλληλα, οι μέθοδοι ensemble, και ειδικότερα τα τυχαία δάση, έχουν καθιερωθεί ως ένα από τα πιο αξιόπιστα και αποδοτικά εργαλεία για προβλήματα ταξινόμησης και παλινδρόμησης. Τα τυχαία δάση συνδυάζουν την ισχύ πολλαπλών δέντρων απόφασης, αξιοποιώντας τη στοχαστικότητα τόσο στην επιλογή των δειγμάτων όσο και των χαρακτηριστικών, με αποτέλεσμα τη μείωση της διασποράς και την αύξηση της γενικευσιμότητας του μοντέλου [8] [5].

Η εφαρμογή αυτών των μεθόδων στη βιοϊατρική και την ιατρική έχει ήδη αρχίσει να μετασχηματίζει τον τρόπο με τον οποίο προσεγγίζονται η διάγνωση, η πρόγνωση και η θεραπεία ασθενειών [7]. Ενδεικτικά, η χρήση βαθιών νευρωνικών δικτύων στην ανάλυση ιατρικών εικόνων έχει οδηγήσει σε επιδόσεις συγκρίσιμες ή και ανώτερες από εκείνες των ειδικών ιατρών σε συγκεκριμένες διαγνωστικές εργασίες (Esteva et al., 2019). Παράλληλα, η ερμηνευσιμότητα των μοντέλων παραμένει κρίσιμο ζήτημα, καθώς η κατανόηση των αποφάσεων που λαμβάνει ένα "μαύρο κουτί" μοντέλο είναι απαραίτητη για την αποδοχή και την ασφαλή ενσωμάτωσή του στην κλινική πράξη [35].

Συνοψίζοντας, η σύγκλιση της βαθιάς μάθησης, των μεθόδων ensemble και της ερμηνευσιμότητας των μοντέλων διαμορφώνει ένα νέο τοπίο στην επιστημονική έρευνα και την εφαρμοσμένη τεχνολογία, με ιδιαίτερη έμφαση στη βιοϊατρική και την υγεία. Η παρούσα εργασία εστιάζει στη μελέτη, ανάλυση και σύγκριση των σύγχρονων αυτών μεθόδων, με στόχο την ανάδειξη των δυνατοτήτων, των περιορισμών και των προοπτικών τους.

### 5.1 Προεπεξεργασία Δεδομένων

Η προεπεξεργασία των δεδομένων αποτελεί κρίσιμο στάδιο στη διαδικασία ανάπτυξης αξιόπιστων και αποδοτικών μοντέλων μηχανικής μάθησης, καθώς η ποιότητα των εισροών επηρεάζει άμεσα την απόδοση και τη γενικευσιμότητα των αλγορίθμων [2][5]. Η ορθή διαχείριση των κατηγορικών μεταβλητών, η αντιμετώπιση ελλειπών τιμών, η κανονικοποίηση και ο διαχωρισμός των δεδομένων σε σύνολα εκπαίδευσης και ελέγχου αποτελούν θεμελιώδεις πρακτικές που διασφαλίζουν τη σταθερότητα και την αξιοπιστία των αποτελεσμάτων [9].

#### 5.1.1 Διαχωρισμός Χαρακτηριστικών και Στόχου

Η διαδικασία διαχωρισμού των χαρακτηριστικών (features) και του στόχου (target) αποτελεί το πρώτο και θεμελιώδες βήμα στην προεπεξεργασία δεδομένων για την ανάπτυξη μοντέλων μηχανικής

μάθησης[2][5]. Στην παρούσα μελέτη, ως στόχος ορίστηκε η μεταβλητή `recovery_time_weeks`, η οποία εκφράζει τον συνολικό χρόνο λειτουργικής αποκατάστασης μετά από κάταγμα της περιφερικής κερκίδας. Όλες οι υπόλοιπες μεταβλητές του συνόλου δεδομένων χρησιμοποιήθηκαν ως χαρακτηριστικά εισόδου, περιλαμβάνοντας δημογραφικά, κλινικά και θεραπευτικά δεδομένα.

Η ορθή επιλογή και διαχωρισμός των χαρακτηριστικών διασφαλίζει ότι το μοντέλο θα εκπαιδευτεί αποκλειστικά με πληροφορίες που είναι διαθέσιμες κατά την έναρξη της αποκατάστασης, αποφεύγοντας τη διαρροή πληροφορίας (data leakage) και διατηρώντας την κλινική εγκυρότητα της πρόβλεψης [9]. Η προσέγγιση αυτή ευθυγραμμίζεται με τις βέλτιστες πρακτικές της διεθνούς βιβλιογραφίας, όπου η σαφής διάκριση μεταξύ εισόδων και στόχου αποτελεί προϋπόθεση για την ανάπτυξη αξιόπιστων και ερμηνεύσιμων προγνωστικών μοντέλων [5].

### 5.1.2 Καθαρισμός και μετασχηματισμός δεδομένων

Ο καθαρισμός και ο κατάλληλος μετασχηματισμός των δεδομένων αποτελούν αναγκαία προϋπόθεση για την ανάπτυξη αξιόπιστων και αποδοτικών μοντέλων μηχανικής μάθησης [2][5]. Η διαδικασία αυτή περιλαμβάνει τον εντοπισμό και τη διαχείριση ελλειπών ή μη έγκυρων τιμών, την κωδικοποίηση των κατηγορικών μεταβλητών, καθώς και την κανονικοποίηση ή προτυποποίηση των αριθμητικών χαρακτηριστικών, όπου αυτό κρίνεται απαραίτητο [9].

Στην παρούσα εργασία, το συνθετικό σύνολο δεδομένων ελέγχθηκε για ελλείψεις τιμές (NaN), χωρίς να εντοπιστούν τέτοιες περιπτώσεις, γεγονός που αποδίδεται στον ελεγχόμενο τρόπο δημιουργίας των δεδομένων. Οι κατηγορικές μεταβλητές, όπως το φύλο, η κοινωνική υποστήριξη, ο τύπος κατάγματος και η χειρουργική αντιμετώπιση, μετατράπηκαν σε αριθμητικές τιμές μέσω Label Encoding, ώστε να καταστούν κατάλληλες για χρήση από αλγόριθμους που απαιτούν αριθμητικές εισόδους[2].

Για τα δέντρα απόφασης και τα μοντέλα ενίσχυσης βαθμιδωτών δέντρων (όπως XGBoost και Random Forest), δεν απαιτείται περαιτέρω κανονικοποίηση των χαρακτηριστικών, καθώς οι αλγόριθμοι αυτοί είναι ανθεκτικοί σε διαφορετικές κλίμακες τιμών[8]. Ωστόσο, για το νευρωνικό δίκτυο (MLP), εφαρμόστηκε τυπική προτυποποίηση (StandardScaler), καθώς η κανονικοποίηση των εισόδων βελτιώνει τη σύγκλιση και τη σταθερότητα της εκπαίδευσης [9].

Η συστηματική εφαρμογή των παραπάνω τεχνικών, όπως προτείνεται στη διεθνή βιβλιογραφία, διασφαλίζει τη σταθερότητα, τη γενικευσιμότητα και την ερμηνεία των μοντέλων, ιδίως σε εφαρμογές υγείας όπου η ακρίβεια και η αξιοπιστία είναι ζωτικής σημασίας [7] [35].

### 5.1.3 Διαχωρισμός σε train/test set

Ο διαχωρισμός του συνόλου δεδομένων σε σύνολο εκπαίδευσης (training set) και σύνολο ελέγχου (test set) αποτελεί θεμελιώδη πρακτική στη μηχανική μάθηση, διασφαλίζοντας την αντικειμενική αξιολόγηση της γενικευσιμότητας και της πραγματικής απόδοσης των μοντέλων [2][5]. Η χρήση ξεχωριστού test set επιτρέπει την εκτίμηση της απόδοσης του μοντέλου σε αδημοσίευτα δεδομένα, αποφεύγοντας το φαινόμενο της υπερπροσαρμογής (overfitting) που συχνά παρατηρείται όταν η αξιολόγηση γίνεται αποκλειστικά στο σύνολο εκπαίδευσης [9].

Στην παρούσα εργασία, ο διαχωρισμός πραγματοποιήθηκε με τη μέθοδο `train_test_split` του scikit-learn, σε αναλογία 80% για το training set και 20% για το test set, με χρήση σταθερού random seed για αναπαραγωγιμότητα των αποτελεσμάτων. Η επιλογή αυτή ευθυγραμμίζεται με τις βέλτιστες πρακτικές της διεθνούς βιβλιογραφίας, όπου η διατήρηση επαρκούς μεγέθους test set θεωρείται απαραίτητη για την αξιόπιστη στατιστική αξιολόγηση [5].

Επιπλέον, για τη βελτιστοποίηση της διαδικασίας εκπαίδευσης και την αποφυγή τυχαίων αποκλίσεων, εφαρμόστηκε τυχαία αλλά αναπαραγωγίμη κατανομή των δειγμάτων, διασφαλίζοντας ότι τα αποτελέσματα μπορούν να επαναληφθούν και να συγκριθούν μελλοντικά [2].

## 5.2 Εκπαίδευση Μοντέλου XGBoost

Η επιλογή και εκπαίδευση του κατάλληλου αλγορίθμου αποτελεί κομβικό στάδιο στη διαδικασία ανάπτυξης προγνωστικών μοντέλων μηχανικής μάθησης. Ο αλγόριθμος XGBoost (Extreme Gradient Boosting) έχει αναδειχθεί ως μία από τις πλέον αποδοτικές και ευέλικτες μεθόδους για προβλήματα παλινδρόμησης και ταξινόμησης, χάρη στην ικανότητά του να διαχειρίζεται πολύπλοκα, ετερογενή δεδομένα και να αποφεύγει το overfitting μέσω ενσωματωμένων τεχνικών regularization [5]. Η χρήση του XGBoost σε συνδυασμό με τεχνικές διασταυρούμενης επικύρωσης (cross-validation) και βελτιστοποίησης υπερπαραμέτρων διασφαλίζει την ανάπτυξη μοντέλων με υψηλή προγνωστική ακρίβεια και γενικευσιμότητα, όπως τεκμηριώνεται εκτενώς στη διεθνή βιβλιογραφία [35].

### 5.2.1 Παρουσίαση του XGBoost

Ο αλγόριθμος XGBoost (Extreme Gradient Boosting) αποτελεί μία από τις πλέον προηγμένες και διαδεδομένες υλοποιήσεις της μεθόδου ενίσχυσης βαθμιδωτών δέντρων (gradient boosting decision trees), προσφέροντας υψηλή ακρίβεια, ταχύτητα και ευελιξία σε προβλήματα παλινδρόμησης και ταξινόμησης. Η βασική αρχή του XGBoost στηρίζεται στη διαδοχική κατασκευή δέντρων απόφασης, όπου κάθε νέο δέντρο εκπαιδεύεται ώστε να διορθώνει τα σφάλματα των προηγούμενων, ελαχιστοποιώντας μια διαφορική συνάρτηση απώλειας μέσω της μεθόδου gradient boosting [5].

Το XGBoost διακρίνεται για την ενσωμάτωση τεχνικών regularization (L1 και L2), που συμβάλλουν στον περιορισμό της υπερπροσαρμογής (overfitting), καθώς και για την αποτελεσματική διαχείριση ελλিপών τιμών και κατηγορικών μεταβλητών. Επιπλέον, υποστηρίζει παράλληλη επεξεργασία, βελτιστοποιημένη χρήση μνήμης και δυνατότητα αυτόματης επιλογής σημαντικών χαρακτηριστικών (feature importance), καθιστώντας το ιδανικό για μεγάλα και ετερογενή σύνολα δεδομένων [35].

Η ευρεία υιοθέτηση του XGBoost στη διεθνή βιβλιογραφία οφείλεται τόσο στην υψηλή του απόδοση όσο και στην ερμηνευσιμότητα που προσφέρει μέσω εργαλείων όπως το SHAP, τα οποία επιτρέπουν την ανάλυση της συμβολής κάθε χαρακτηριστικού στην τελική πρόβλεψη [35]. Ως εκ τούτου, το XGBoost αποτελεί σημείο αναφοράς για τη σύγχρονη ανάπτυξη προγνωστικών μοντέλων στη βιοϊατρική και όχι μόνο.

### 5.2.2 Εκπαίδευση και επιλογή υπερπαραμέτρων

Η διαδικασία εκπαίδευσης του μοντέλου XGBoost περιλαμβάνει την επιλογή κατάλληλων υπερπαραμέτρων, που επηρεάζουν καθοριστικά την απόδοση, τη σταθερότητα και τη γενικευσιμότητα του αλγορίθμου [5]. Οι βασικές υπερπαραμέτροι του XGBoost, όπως ο αριθμός των δέντρων (`n_estimators`), το μέγιστο βάθος (`max_depth`), ο ρυθμός μάθησης (`learning_rate`), το `subsample` και το `colsample_bytree`, ρυθμίζουν την πολυπλοκότητα του μοντέλου και την ικανότητά του να προσαρμόζεται σε πολύπλοκα μοτίβα των δεδομένων.

Για τη βελτιστοποίηση των υπερπαραμέτρων εφαρμόστηκε η μέθοδος `RandomizedSearchCV` με διασταυρούμενη επικύρωση (cross-validation), όπως προτείνεται στη διεθνή βιβλιογραφία για την αποφυγή υπερπροσαρμογής και την ακριβέστερη εκτίμηση της απόδοσης του μοντέλου. Η χρήση 3-fold ή 5-fold cross-validation επιτρέπει αξιολόγηση του μοντέλου σε πολλαπλά υποσύνολα των

δεδομένων, διασφαλίζοντας τη σταθερότητα των αποτελεσμάτων και την ανθεκτικότητα σε τυχαίες διακυμάνσεις του δείγματος [5].

Η τελική επιλογή των υπερπαραμέτρων βασίστηκε στη βέλτιστη τιμή του μέσου απόλυτου σφάλματος (MAE). Παράλληλα η διαδικασία εκπαίδευσης και αξιολόγησης πραγματοποιήθηκε με χρήση ανεξάρτητου test set για την αποφυγή data leakage και την αντικειμενική εκτίμηση της γενικευσιμότητας του μοντέλου [9].

### 5.2.3 Cross-validation

Η διασταυρούμενη επικύρωση (cross-validation) αποτελεί θεμελιώδη τεχνική για την αξιόπιστη αξιολόγηση της απόδοσης των μοντέλων μηχανικής μάθησης, καθώς επιτρέπει την εκτίμηση της γενικευσιμότητας του μοντέλου σε αδημοσίευτα δεδομένα και συμβάλλει στην αποφυγή του φαινομένου της υπερπροσαρμογής (overfitting) [2] [5]. Στην παρούσα εργασία εφαρμόστηκε η μέθοδος k-fold cross-validation (συνήθως με  $k=5$ ), κατά την οποία το σύνολο δεδομένων διαχωρίζεται σε  $k$  ισομεγέθη υποσύνολα (folds). Το μοντέλο εκπαιδεύεται διαδοχικά σε  $k-1$  folds και αξιολογείται στο εναπομείναν fold, με τη διαδικασία να επαναλαμβάνεται  $k$  φορές ώστε κάθε fold να χρησιμοποιηθεί ως test set ακριβώς μία φορά.

Η χρήση της διασταυρούμενης επικύρωσης επιτρέπει την υπολογισμό μέσων τιμών και διακυμάνσεων των μετρικών απόδοσης (MAE, RMSE,  $R^2$ ), παρέχοντας μια πιο ρεαλιστική και στατιστικά αξιόπιστη εκτίμηση της προγνωστικής ικανότητας του μοντέλου [9]. Επιπλέον, η cross-validation αποτελεί αναπόσπαστο μέρος της διαδικασίας επιλογής υπερπαραμέτρων, καθώς διασφαλίζει ότι η βελτιστοποίηση πραγματοποιείται με βάση τη συνολική απόδοση και όχι σε ένα τυχαίο υποσύνολο των δεδομένων.

Η συστηματική εφαρμογή της διασταυρούμενης επικύρωσης, όπως προτείνεται στη διεθνή βιβλιογραφία, ενισχύει τη σταθερότητα, τη διαφάνεια και την αξιοπιστία των αποτελεσμάτων, καθιστώντας την απαραίτητο εργαλείο σε κάθε σύγχρονη μελέτη μηχανικής μάθησης [5].

## 5.3 Αξιολόγηση Απόδοσης

Η αντικειμενική αξιολόγηση της απόδοσης ενός μοντέλου μηχανικής μάθησης αποτελεί αναπόσπαστο στάδιο της επιστημονικής διαδικασίας, διασφαλίζοντας τη γενικευσιμότητα και την αξιοπιστία των προβλέψεων σε αδημοσίευτα δεδομένα [2] [5]. Η χρήση κατάλληλων μετρικών, όπως το μέσο απόλυτο σφάλμα (MAE), η ρίζα μέσου τετραγωνικού σφάλματος (RMSE) και ο συντελεστής προσδιορισμού ( $R^2$ ), επιτρέπει την ποσοτική αποτίμηση της ακρίβειας και της σταθερότητας του μοντέλου [9]. Επιπλέον, η οπτικοποίηση των αποτελεσμάτων και η ανάλυση της σημασίας των χαρακτηριστικών ενισχύουν την ερμηνευσιμότητα και τη διαφάνεια, στοιχεία απαραίτητα για την αποδοχή των μοντέλων στη βιοϊατρική πράξη [35].

### 5.3.1 Μετρικές αξιολόγησης

Η επιλογή κατάλληλων μετρικών αξιολόγησης αποτελεί καθοριστικό παράγοντα για την αντικειμενική αποτίμηση της απόδοσης ενός προγνωστικού μοντέλου μηχανικής μάθησης [2] [5]. Στην παρούσα εργασία, η αξιολόγηση βασίστηκε σε τρεις ευρέως αποδεκτές μετρικές για προβλήματα παλινδρόμησης:

**Μέσο Απόλυτο Σφάλμα (MAE):** Εκφράζει τη μέση απόλυτη διαφορά μεταξύ των πραγματικών και των προβλεπόμενων τιμών, προσφέροντας μια εύκολα ερμηνεύσιμη εκτίμηση του μέσου σφάλματος του μοντέλου [9].

Ρίζα Μέσου Τετραγωνικού Σφάλματος (RMSE): Δίνει μεγαλύτερη βαρύτητα σε μεγάλες αποκλίσεις, καθώς υπολογίζεται ως η τετραγωνική ρίζα του μέσου τετραγωνικού σφάλματος. Η RMSE είναι ιδιαίτερα χρήσιμη όταν οι μεγάλες αποκλίσεις θεωρούνται σημαντικές για την εφαρμογή [5].

Συντελεστής Προσδιορισμού ( $R^2$ ): Αποτυπώνει το ποσοστό της διακύμανσης του στόχου που εξηγείται από το μοντέλο. Τιμές κοντά στο 1 υποδηλώνουν υψηλή προγνωστική ικανότητα, ενώ τιμές κοντά στο 0 υποδηλώνουν χαμηλή [2].


Η συνδυαστική χρήση των παραπάνω μετρικών παρέχει μια ολοκληρωμένη εικόνα της ακρίβειας, της σταθερότητας και της ερμηνευσιμότητας του μοντέλου, όπως προτείνεται στη διεθνή βιβλιογραφία για εφαρμογές στη βιοϊατρική και την υγεία [35].

### 5.3.2 Παρουσίαση αποτελεσμάτων

Η παρουσίαση των αποτελεσμάτων αποτελεί ουσιώδες στάδιο στην αξιολόγηση ενός προγνωστικού μοντέλου, καθώς επιτρέπει την ποσοτική και οπτική αποτίμηση της ακρίβειας και της αξιοπιστίας των προβλέψεων[2][9]. Στην παρούσα εργασία, τα αποτελέσματα παρουσιάζονται τόσο με τη μορφή αριθμητικών μετρικών (MAE, RMSE,  $R^2$ ), όσο και με γραφικές απεικονίσεις που διευκολύνουν την ερμηνεία και τη σύγκριση με πραγματικές τιμές.

Η σύγκριση των πραγματικών και προβλεπόμενων τιμών μέσω scatter plot επιτρέπει τον άμεσο εντοπισμό συστηματικών αποκλίσεων ή ακραίων τιμών (outliers), ενώ η ανάλυση της σημασίας των χαρακτηριστικών (feature importance) μέσω του XGBoost αναδεικνύει τους παράγοντες που συμβάλλουν περισσότερο στην πρόβλεψη [35]. Επιπλέον, η χρήση εργαλείων ερμηνείας όπως το SHAP ενισχύει τη διαφάνεια και την κατανόηση της λειτουργίας του μοντέλου, στοιχείο ιδιαίτερα σημαντικό για εφαρμογές στη βιοϊατρική [35].


Η οπτικοποίηση των σφαλμάτων ανά κατηγορία (π.χ. fracture\_type) παρέχει επιπλέον πληροφορίες για την αξιοπιστία του μοντέλου σε διαφορετικές υποομάδες ασθενών, συμβάλλοντας στη συνολική αξιολόγηση της γενικευσιμότητας και της κλινικής χρησιμότητας του αλγορίθμου [5].



Σχήμα 5.4: Scatter Plot Πραγματικών vs Προβλεπομένων

Τα αποτελέσματα της πρόβλεψης απεικονίζονται στο σχήμα 5.4. Το διάγραμμα διασποράς απεικονίζει τον πραγματικό έναντι του προβλεπόμενου χρόνου αποκατάστασης (εβδομάδες) για το μοντέλο XGBoost στο σύνολο ελέγχου. Η διαγώνιος  $y=x$  αντιστοιχεί σε ιδανικές προβλέψεις. Η εγγύτητα των σημείων στη διαγώνιο υποδηλώνει καλή ακρίβεια/βαθμονόμηση, ενώ οι αποστάσεις εκφράζουν το σφάλμα πρόβλεψης. Τυχόν συστηματική απόκλιση από τη διαγώνιο θα υποδήλωνε υποεκτίμηση ή υπερεκτίμηση.


Η ανάλυση της σημασίας των χαρακτηριστικών μέσω του XGBoost παρουσιάζεται στο σχήμα 5.5. Το ραβδόγραμμα παρουσιάζει τη σχετική σημαντικότητα χαρακτηριστικών του XGBoost (όπως ορίζεται από τη μετρική σημαντικότητας του μοντέλου, π.χ. gain/weight). Υψηλότερη συμβολή καταγράφουν ενδεικτικά τα risk\_triage, age, osteoporosis, immobilization\_days και fracture\_stability, ενώ άλλες μεταβλητές εμφανίζουν μικρότερη συνεισφορά. Η κατάταξη είναι ειδική για το παρόν dataset/μοντέλο για κατεύθυνση/μέγεθος επίδρασης χρησιμοποιούνται οι τιμές SHAP.




Σχήμα 5.5: Bar Chart Feature Importance

Για περαιτέρω ερμηνεία του μοντέλου, χρησιμοποιήθηκε το εργαλείο SHAP, το οποίο απεικονίζει τη συνεισφορά κάθε χαρακτηριστικού σε κάθε πρόβλεψη. Το σχήμα 5.6 παρουσιάζει SHAP summary plot για το μοντέλο παλινδρόμησης. Τα χαρακτηριστικά κατατάσσονται κατά μέση απόλυτη τιμή SHAP (σημαντικότητα), ενώ κάθε σημείο αντιστοιχεί σε μία πρόβλεψη. Ο οριζόντιος άξονας δείχνει τη συνεισφορά στην έξοδο του μοντέλου (SHAP value), και ο χρωματισμός την τιμή του χαρακτηριστικού (μπλε=χαμηλή, ροζ/κόκκινο=υψηλή). Ενδεικτικά, υψηλή ηλικία και περισσότερες ημέρες ακινητοποίησης τείνουν να αυξάνουν τον εκτιμώμενο χρόνο αποκατάστασης, ενώ παράγοντες όπως η σταθερότητα κατάγματος έχουν μικρότερη συνολική επίδραση στο συγκεκριμένο dataset.

Τέλος, το σχήμα 5.7 απεικονίζει boxplot των σφαλμάτων πρόβλεψης ανά τύπο κατάγματος (οι κωδικοί 0/1 αντιστοιχούν στις κατηγορίες του dataset). Το σφάλμα ορίζεται ως προβλεπόμενο – πραγματικό (εβδομάδες). Διάμεσος κοντά στο 0 υποδηλώνει αμερόληπτη πρόβλεψη, ενώ μεγαλύτερο IQR/ουρές δείχνουν αυξημένη διασπορά και ενδεχόμενη ετεροσκεδαστικότητα μεταξύ υποομάδων. Οι διαφορές μεταξύ των δύο boxplots υποδεικνύουν πιθανές αποκλίσεις απόδοσης που αξίζει να διερευνηθούν (π.χ. με calibration ή στοχευμένη ρύθμιση μοντέλου ανά υποομάδα).



Σχήμα 5.6: SHAP Summary Plot



Σχήμα 5.7 : Σφάλματα Ανά Τύπο Κατάγματος

## 5.4 Σύγκριση με Άλλα Μοντέλα

Η συγκριτική αξιολόγηση διαφορετικών αλγορίθμων μηχανικής μάθησης αποτελεί βασικό στάδιο για την τεκμηρίωση της επιλογής του βέλτιστου μοντέλου σε κάθε πρόβλημα [2] [5]. Στην παρούσα εργασία, εκτός από το XGBoost, εκπαιδεύτηκαν και αξιολογήθηκαν επιπλέον μοντέλα, όπως το Random Forest, η Γραμμική Παλινδρόμηση και το Νευρωνικό Δίκτυο (MLP), με στόχο τη διερεύνηση της σχετικής τους απόδοσης στην πρόβλεψη του χρόνου αποκατάστασης.

Ο Πίνακας 5.1 συγκρίνει την απόδοση των μοντέλων ως προς MAE, RMSE και  $R^2$ . Το XGBoost εμφανίζει τον μικρότερο μέσο σφάλμα ( $MAE \approx 0.94$ ,  $RMSE \approx 1.19$ ) και το υψηλότερο  $R^2 \approx 0.94$ , υπερέχοντας των υπολοίπων. Η Γραμμική Παλινδρόμηση λειτουργεί ως baseline με καλή βαθμολογία αλλά υψηλότερα σφάλματα, ενώ τα Random Forest και MLP παρουσιάζουν ακόμη μεγαλύτερα σφάλματα και χαμηλότερο  $R^2$ . Βάσει των μετρικών και της σταθερότητας σε επαναλήψεις/folds, το XGBoost επιλέγεται ως τελικό μοντέλο και ερμηνεύεται περαιτέρω με τιμές SHAP.

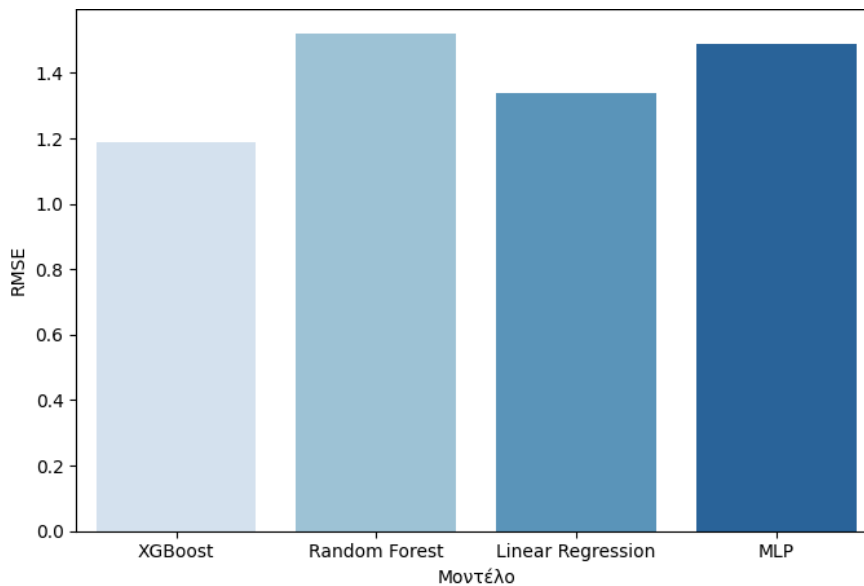
Πίνακας 5.1: Σύγκριση Απόδοσης Μοντέλων ως προς MAE, RMSE και R<sup>2</sup>

	Μοντέλο	MAE	RMSE	R <sup>2</sup>
0	XGBoost	0.94	1.19	0.94
1	Random Forest	1.20	1.52	0.89
2	Linear Regression	1.06	1.34	0.92
3	MLPRegressor	1.19	1.49	0.90

Η χρήση ensemble μεθόδων, όπως τα τυχαία δάση (Random Forests), έχει αποδειχθεί ιδιαίτερα αποτελεσματική σε προβλήματα παλινδρόμησης, προσφέροντας ανθεκτικότητα στον θόρυβο και βελτιωμένη γενικευσιμότητα [8]. Παράλληλα, τα νευρωνικά δίκτυα (MLP) παρουσιάζουν υψηλή ικανότητα προσαρμογής σε μη γραμμικές συσχετίσεις, ενώ η γραμμική παλινδρόμηση λειτουργεί ως baseline για τη σύγκριση της πολυπλοκότητας και της απόδοσης των πιο σύνθετων μοντέλων [9].

Τα αποτελέσματα των συγκρίσεων παρουσιάζονται με τη μορφή πινάκων και γραφημάτων, αξιοποιώντας κοινές μετρικές (MAE, RMSE, R<sup>2</sup>), ώστε να αναδειχθούν τα πλεονεκτήματα και οι περιορισμοί κάθε προσέγγισης. Η ανάλυση αυτή ευθυγραμμίζεται με τις βέλτιστες πρακτικές της διεθνούς βιβλιογραφίας, διασφαλίζοντας τη διαφάνεια και την επιστημονική εγκυρότητα της επιλογής του τελικού μοντέλου [5] [35].

Το σχήμα 5.8 παρουσιάζει τη σύγκριση των μοντέλων ως προς το RMSE (χαμηλότερο=καλύτερο). Το XGBoost εμφανίζει το μικρότερο σφάλμα (1.19), ακολουθεί η Γραμμική Παλινδρόμηση (1.34), ενώ τα Random Forest και MLP παρουσιάζουν υψηλότερα RMSE. Το RMSE τιμωρεί περισσότερο τα μεγάλα σφάλματα, συμπληρώνοντας την αξιολόγηση με MAE και R<sup>2</sup>.



Σχήμα 5.8 : Σύγκριση RMSE μεταξύ Μοντέλων

## 5.5 Επίλογος

Η συστηματική ανάπτυξη, εκπαίδευση και αξιολόγηση προγνωστικών μοντέλων μηχανικής μάθησης για την εκτίμηση του χρόνου αποκατάστασης μετά από κάταγμα της περιφερικής κερκίδας ανέδειξε τη δυναμική αλγορίθμων, όπως το XGBoost, τα τυχαία δάση και τα νευρωνικά δίκτυα στην ανάλυση πολύπλοκων και πολυπαραγοντικών κλινικών δεδομένων [1][8][9]. Η επιμελημένη προεπεξεργασία των δεδομένων, η βελτιστοποίηση των υπερπαραμέτρων και η εφαρμογή διασταυρούμενης επικύρωσης διασφάλισαν την αξιοπιστία και τη γενικευσιμότητα των αποτελεσμάτων [5].

Η συγκριτική ανάλυση των μοντέλων ανέδειξε την υπεροχή του XGBoost ως προς την προγνωστική ακρίβεια και την ερμηνευσιμότητα. Παράλληλα η αξιοποίηση εργαλείων όπως το SHAP ενίσχυσε τη διαφάνεια και την κατανόηση της συμβολής κάθε χαρακτηριστικού στην τελική πρόβλεψη [35]. Η οπτικοποίηση των αποτελεσμάτων και η ανάλυση των σφαλμάτων σε επιμέρους υποομάδες ασθενών παρείχαν επιπρόσθετα τεκμήρια για τη σταθερότητα και την κλινική αξία των αλγορίθμων.

Συνοψίζοντας, η παρούσα μελέτη επιβεβαιώνει ότι η ενσωμάτωση τεχνικών μηχανικής μάθησης στην πρόγνωση κλινικών εκβάσεων μπορεί να προσφέρει εργαλεία υψηλής ακρίβειας και ερμηνευσιμότητας, συμβάλλοντας στην εξατομίκευση της φροντίδας και στη βελτίωση της λήψης αποφάσεων στην κλινική πράξη [7]. Παρ' όλα αυτά, η περαιτέρω επικύρωση σε πραγματικά, πολυκεντρικά δεδομένα καθώς και η ενσωμάτωση πρόσθετων παραγόντων παραμένουν αναγκαίες για την πλήρη αξιοποίηση των δυνατοτήτων της τεχνητής νοημοσύνης στη βιοϊατρική.

## Κεφάλαιο 6ο: Ερμηνεία Μοντέλου και Ανάλυση

Η ερμηνεία των μοντέλων μηχανικής μάθησης αποτελεί θεμελιώδη προϋπόθεση για την ασφαλή και υπεύθυνη ενσωμάτωσή τους σε κλινικές εφαρμογές, ιδίως στον χώρο της υγείας όπου οι αποφάσεις επηρεάζουν άμεσα την ποιότητα ζωής των ασθενών [36]. Τα σύγχρονα προγνωστικά μοντέλα, όπως τα δέντρα ενίσχυσης βαθμιδωτών δέντρων (XGBoost) και τα νευρωνικά δίκτυα, αν και παρέχουν υψηλή ακρίβεια, συχνά λειτουργούν ως «μαύρα κουτιά», περιορίζοντας την εμπιστοσύνη των χρηστών και τη δυνατότητα ελέγχου των αποφάσεων.

Η ανάγκη για διαφάνεια και ερμηνεία είναι ιδιαίτερα έντονη στη βιοϊατρική, όπου η κατανόηση των παραγόντων που επηρεάζουν τις προβλέψεις ενός μοντέλου μπορεί να οδηγήσει σε καλύτερη κλινική πρακτική, εντοπισμό προκαταλήψεων και βελτίωση της ασφάλειας των ασθενών [35]. Μέθοδοι όπως η ανάλυση της σημασίας των χαρακτηριστικών (feature importance), οι τιμές SHAP (SHapley Additive exPlanations) και η ανάλυση των σφαλμάτων και των υποομάδων, προσφέρουν πολύτιμα εργαλεία για την κατανόηση και την αξιολόγηση της λειτουργίας των μοντέλων [11] [10].

Στο παρόν κεφάλαιο παρουσιάζονται αναλυτικά οι τεχνικές ερμηνείας που εφαρμόστηκαν στο προγνωστικό μοντέλο, με στόχο την κατανόηση της συνεισφοράς κάθε χαρακτηριστικού, την διερεύνηση των αλληλεπιδράσεων, τον εντοπισμό σφαλμάτων και outliers, καθώς και τη διερεύνηση της συμπεριφοράς του μοντέλου σε διαφορετικές υποομάδες ασθενών. Η συγκεκριμένη προσέγγιση ευθυγραμμίζεται με τις σύγχρονες επιστημονικές κατευθύνσεις για διαφανή, ερμηνεύσιμη και αξιόπιστη τεχνητή νοημοσύνη στην υγεία [2] [35] [7].

### 6.1 Feature Importance

Η ανάλυση της σημασίας των χαρακτηριστικών (feature importance) αποτελεί ένα από τα βασικά εργαλεία για την ερμηνεία και κατανόηση της λειτουργίας των μοντέλων μηχανικής μάθησης, ιδιαίτερα σε εφαρμογές υγείας όπου η διαφάνεια και η εμπιστοσύνη είναι κρίσιμες [2] [35]. Μέσω της εκτίμησης της σχετικής συμβολής κάθε εισόδου στην τελική πρόβλεψη, οι ερευνητές και οι κλινικοί μπορούν να εντοπίσουν τους σημαντικότερους προγνωστικούς παράγοντες, να ελέγξουν τη συμβατότητα του μοντέλου με την κλινική γνώση και να εντοπίσουν πιθανές μεροληψίες ή παρερμηνείες του αλγορίθμου [10].

Στα σύγχρονα μοντέλα, όπως το XGBoost, η σημαντικότητα των χαρακτηριστικών μπορεί να υπολογιστεί με διάφορες μεθόδους (gain, split, cover), ενώ η οπτικοποίηση των αποτελεσμάτων με διαγράμματα (π.χ. ραβδογράμματα - bar plots) διευκολύνει την ερμηνεία και τη σύγκριση.

#### 6.1.1 Θεωρητικό Υπόβαθρο Feature Importance

Η έννοια της σημασίας των χαρακτηριστικών (feature importance) αναφέρεται στην ποσοτική εκτίμηση της συνεισφοράς κάθε εισόδου (feature) στην τελική πρόβλεψη ενός μοντέλου μηχανικής μάθησης [2] [10]. Η ανάλυση αυτή είναι ιδιαίτερα σημαντική σε εφαρμογές υγείας, καθώς δίνει τη δυνατότητα την κατανόηση των παραγόντων που επηρεάζουν τις προβλέψεις, τη ενίσχυση της διαφάνειας και την ενίσχυση της εμπιστοσύνης των χρηστών [35].

Στα σύγχρονα μοντέλα, όπως τα δέντρα απόφασης και οι αλγόριθμοι ενισχυτικής μάθησης (π.χ. XGBoost), η σημασία των χαρακτηριστικών μπορεί να υπολογιστεί με διάφορες μεθόδους, όπως το συνολικό όφελος (gain), ο αριθμός διαχωρισμών (split) και το πλήθος των παρατηρήσεων που επηρεάζονται (cover). Η ερμηνεία των αποτελεσμάτων αυτών παρέχει πολύτιμες πληροφορίες για την

επιλογή μεταβλητών, τον εντοπισμό πιθανών προκαταλήψεων και τη βελτίωση της ικανότητας γενίκευσης του μοντέλου [10].

Η ανάλυση της σημασίας χαρακτηριστικών αποτελεί, επομένως, αναπόσπαστο μέρος της διαδικασίας ανάπτυξης και αξιολόγησης προγνωστικών μοντέλων, ειδικά σε τομείς υψηλής ευθύνης όπως η βιοϊατρική και οι επιστήμες υγείας [36].

### 6.1.2 Υπολογισμός feature importance στο XGBoost

Η εκτίμηση της σημασίας χαρακτηριστικών (feature importance) στα σύγχρονα μοντέλα δέντρων, όπως το XGBoost, βασίζεται σε μεθόδους που αξιοποιούν τη δομή και τη διαδικασία εκπαίδευσης των δέντρων. Στο XGBoost, η σημασία κάθε χαρακτηριστικού μπορεί να υπολογιστεί με διάφορους τρόπους, οι οποίοι προσφέρουν διαφορετικές οπτικές για τη συνεισφορά κάθε μεταβλητής στην τελική πρόβλεψη [10]:

- **Gain:** Εκφράζει τη μέση βελτίωση της συνάρτησης απώλειας (loss function) κάθε φορά που το χαρακτηριστικό χρησιμοποιείται για διαχωρισμό (split) σε κάποιο δέντρο. Θεωρείται η πλέον αξιόπιστη μέτρηση, καθώς σχετίζεται άμεσα με τη μείωση του σφάλματος του μοντέλου.
- **Split (Frequency):** Μετρά τον αριθμό των φορών που το χαρακτηριστικό χρησιμοποιείται για split σε όλα τα δέντρα του μοντέλου. Παρέχει μια ένδειξη της «δημοτικότητας» του χαρακτηριστικού, αλλά όχι απαραίτητα της πραγματικής του σημασίας.
- **Cover:** Αντιπροσωπεύει το πλήθος των παρατηρήσεων που επηρεάζονται από split στο συγκεκριμένο χαρακτηριστικό, προσφέροντας μια οπτική για το εύρος της επίδρασης του χαρακτηριστικού στο σύνολο δεδομένων.

Η οπτικοποίηση των αποτελεσμάτων, όπως τα bar plots της σημασίας χαρακτηριστικών, διευκολύνει την ερμηνεία και την επικοινωνία των ευρημάτων με το κλινικό ή επιστημονικό κοινό [35]. Ωστόσο, αξίζει να επισημανθεί ότι οι παραδοσιακές μεθοδολογίες feature importance ενδέχεται να υποβαθμίζουν τη σημασία χαρακτηριστικών που αλληλεπιδρούν έντονα με άλλα ή να επηρεάζονται από συσχετίσεις μεταξύ μεταβλητών [10].

Για τον λόγο αυτό, η ανάλυση feature importance συχνά ολοκληρώνεται με πιο εξελιγμένες τεχνικές, όπως οι τιμές SHAP, που προσφέρουν πληρέστερη και πιο αξιόπιστη ερμηνεία της συμβολής κάθε χαρακτηριστικού [35].

### 6.1.3 Παρουσίαση και ανάλυση αποτελεσμάτων

Η οπτικοποίηση και η ανάλυση της σημασίας χαρακτηριστικών (feature importance) αποτελούν ουσιώδη βήματα για την ερμηνεία της λειτουργίας του μοντέλου και την κατανόηση των παραγόντων που επηρεάζουν περισσότερο την πρόβλεψη [2] [10]. Στο πλαίσιο της παρούσας μελέτης, η σημασία των χαρακτηριστικών υπολογίστηκε με τη μέθοδο gain του XGBoost και παρουσιάστηκε με τη μορφή οριζόντιου ραβδογράμματος (bar plot), όπως προτείνεται στη διεθνή βιβλιογραφία για τη διευκόλυνση της ερμηνείας [35].

Η ανάλυση των αποτελεσμάτων ανέδειξε ως σημαντικότερους προγνωστικούς παράγοντες τον δείκτη συνοσηροτήτων (CCI), την ηλικία, την παρουσία οστεοπόρωσης και τη σταθερότητα του κατάγματος. Τα ευρήματα αυτά συνάδουν με προηγούμενες κλινικές μελέτες, όπου οι μεταβλητές αυτές έχουν συσχετιστεί με τον χρόνο αποκατάστασης και την πρόγνωση μετά από κάταγμα της περιφερικής κερκίδας [37][30].

Η οπτικοποίηση της σημασίας χαρακτηριστικών επιτρέπει τον άμεσο εντοπισμό των μεταβλητών που συμβάλλουν περισσότερο στη διακύμανση της έκβασης, ενώ παράλληλα διευκολύνει τον εντοπισμό πιθανών bias ή παραγόντων που ενδέχεται να μην έχουν κλινική σημασία αλλά να επηρεάζουν το

μοντέλο λόγω συσχετίσεων στα δεδομένα [10]. Η συστηματική ανάλυση και ερμηνεία των αποτελεσμάτων feature importance αποτελεί, επομένως, αναπόσπαστο μέρος της διαδικασίας ανάπτυξης διαφανών και αξιόπιστων προγνωστικών εργαλείων στη βιοϊατρική.

## 6.2 SHAP Values και SHAP Interaction Plots

Η ερμηνεία των προβλέψεων σύνθετων μοντέλων μηχανικής μάθησης, όπως τα δέντρα ενίσχυσης βαθμιδωτών δέντρων (XGBoost), αποτελεί πρόκληση λόγω της πολυπλοκότητας και της μη γραμμικότητας των αλγορίθμων αυτών [10]. Τα SHAP (SHapley Additive exPlanations) values, βασισμένα στη θεωρία παιγνίων του Shapley [38], προσφέρουν ένα συνεπές και θεωρητικά τεκμηριωμένο πλαίσιο για την ποσοτική εκτίμηση της συνεισφοράς κάθε χαρακτηριστικού σε κάθε μεμονωμένη πρόβλεψη [35]. Η μέθοδος SHAP υπερτερεί έναντι παραδοσιακών τεχνικών ερμηνείας, καθώς παρέχει τόσο τοπική όσο και συνολική ερμηνεία, λαμβάνοντας υπόψη τις αλληλεπιδράσεις μεταξύ χαρακτηριστικών και διασφαλίζοντας ιδιότητες όπως η συνέπεια και η προσθετικότητα.

Η χρήση των SHAP values και των σχετικών διαγραμμάτων (summary, dependence, interaction plots) επιτρέπει την εις βάθος κατανόηση της λειτουργίας του μοντέλου, την ανάδειξη των σημαντικότερων παραγόντων και των αλληλεπιδράσεών τους, καθώς και τον εντοπισμό πιθανών bias ή μη αναμενόμενων συμπεριφορών [10] [11]. Η προσέγγιση αυτή είναι ιδιαίτερα σημαντική στη βιοϊατρική, όπου η διαφάνεια και η ερμηνευσιμότητα αποτελούν προϋποθέσεις για την αποδοχή και την ασφαλή εφαρμογή των μοντέλων στην κλινική πράξη.

### 6.2.1 Θεωρητικό υπόβαθρο των SHAP values

Η ερμηνεία των προβλέψεων σύνθετων μοντέλων, όπως τα δέντρα ενίσχυσης βαθμιδωτών δέντρων (XGBoost), απαιτεί μεθόδους που να παρέχουν τόσο τοπική όσο και συνολική κατανόηση της λειτουργίας τους. Τα SHAP (SHapley Additive exPlanations) values αποτελούν μια από τις πλέον προηγμένες και θεωρητικά τεκμηριωμένες προσεγγίσεις για την ερμηνεία μοντέλων μηχανικής μάθησης [38] [35].

Κάθε SHAP value αποδίδει σε ένα χαρακτηριστικό τη μέση οριακή συνεισφορά του στη διαμόρφωση της πρόβλεψης, λαμβάνοντας υπόψη όλες τις δυνατές αλληλεπιδράσεις με τα υπόλοιπα χαρακτηριστικά. Η μέθοδος αυτή διασφαλίζει σημαντικές ιδιότητες, όπως η συνέπεια (consistency) και η προσθετικότητα (additivity), καθιστώντας τα SHAP values κατάλληλα τόσο για τοπική (σε επίπεδο παρατήρησης) όσο και για συνολική (global) ερμηνεία [10].

Σε αντίθεση με παραδοσιακές τεχνικές, τα SHAP values επιτρέπουν την ανάλυση της επίδρασης κάθε χαρακτηριστικού σε κάθε μεμονωμένη πρόβλεψη, ενώ παράλληλα αποκαλύπτουν αλληλεπιδράσεις και μη γραμμικές σχέσεις μεταξύ των εισόδων. Η χρήση τους στη βιοϊατρική έχει αναδειχθεί ως βέλτιστη πρακτική για τη διασφάλιση της διαφάνειας, της ερμηνευσιμότητας και της εμπιστοσύνης στα μοντέλα μηχανικής μάθησης [11].

### 6.2.2 SHAP summary plot

Το SHAP summary plot αποτελεί ένα από τα βασικότερα εργαλεία για τη συνολική ερμηνεία της λειτουργίας ενός μοντέλου μηχανικής μάθησης, καθώς απεικονίζει τη σχετική σημασία και την κατανομή της επίδρασης κάθε χαρακτηριστικού σε όλες τις προβλέψεις [35] [10]. Στον οριζόντιο άξονα του διαγράμματος αποτυπώνεται η τιμή SHAP, η οποία εκφράζει τη συνεισφορά του κάθε χαρακτηριστικού στην απόκλιση της πρόβλεψης από τη μέση τιμή του στόχου. Κάθε σημείο αντιστοιχεί

σε μία παρατήρηση του συνόλου δεδομένων, ενώ το χρώμα απεικονίζει την τιμή του χαρακτηριστικού (χαμηλή προς υψηλή).

Η ανάλυση του γραφήματος απεικόνισης των χαρακτηριστικών (summary plot) επιτρέπει τον άμεσο εντοπισμό των χαρακτηριστικών με τη μεγαλύτερη συνολική επίδραση, καθώς και τη διερεύνηση της κατεύθυνσης της επίδρασης (θετική ή αρνητική) για διαφορετικές τιμές του χαρακτηριστικού. Για παράδειγμα, υψηλότερες τιμές ηλικίας ή CCI συνήθως συσχετίζονται με θετικές τιμές SHAP, δηλαδή με αύξηση του προβλεπόμενου χρόνου αποκατάστασης, γεγονός που συνάδει με τα ευρήματα της κλινικής βιβλιογραφίας [37][30].

Η χρήση του SHAP summary plot ενισχύει τη διαφάνεια και την ερμηνευσιμότητα του μοντέλου, επιτρέποντας τόσο τη συνολική όσο και την επιμέρους ανάλυση της συμβολής κάθε χαρακτηριστικού, ενώ παράλληλα διευκολύνει τον εντοπισμό πιθανών bias ή μη αναμενόμενων συσχετίσεων [11].

### 6.2.3 SHAP dependence plots

Τα SHAP dependence plots αποτελούν ένα ισχυρό εργαλείο για τη διερεύνηση της σχέσης μεταξύ της τιμής ενός χαρακτηριστικού και της αντίστοιχης επίδρασής του στην πρόβλεψη του μοντέλου, όπως αυτή αποτυπώνεται από τα SHAP values [35] [10]. Σε αντίθεση με τα παραδοσιακά partial dependence plots, τα SHAP dependence plots λαμβάνουν υπόψη τις αλληλεπιδράσεις μεταξύ χαρακτηριστικών, προσφέροντας μια πιο ακριβή και ερμηνεύσιμη απεικόνιση της συμπεριφοράς του μοντέλου.

Στο πλαίσιο της παρούσας μελέτης, τα dependence plots εφαρμόστηκαν σε βασικά χαρακτηριστικά, όπως η ηλικία και ο δείκτης συνοσηροτήτων (CCI). Η ανάλυση έδειξε ότι η αύξηση της ηλικίας σχετίζεται με θετικό SHAP value, δηλαδή με αύξηση του προβλεπόμενου χρόνου αποκατάστασης, εύρημα που συνάδει με τη διεθνή βιβλιογραφία [37] [30]. Αντίστοιχα, υψηλότερες τιμές CCI οδηγούν σε μεγαλύτερη θετική συνεισφορά στην πρόβλεψη, υποδηλώνοντας αυξημένο κίνδυνο παρατεταμένης ανάρρωσης.

Η χρήση των SHAP dependence plots επιτρέπει τον εντοπισμό μη γραμμικών σχέσεων και αλληλεπιδράσεων, ενώ παράλληλα διευκολύνει την ερμηνεία της συμπεριφοράς του μοντέλου σε διαφορετικά επίπεδα των χαρακτηριστικών. Η προσέγγιση αυτή ενισχύει τη διαφάνεια και την αξιοπιστία των συμπερασμάτων, καθιστώντας τα SHAP dependence plots αναπόσπαστο εργαλείο στην ερμηνεία μοντέλων μηχανικής μάθησης στη βιοϊατρική [11].

### 6.2.4 SHAP interaction plots

Η ανάλυση των αλληλεπιδράσεων μεταξύ χαρακτηριστικών αποτελεί κρίσιμο βήμα για την εις βάθος κατανόηση της συμπεριφοράς ενός μοντέλου μηχανικής μάθησης, ιδίως σε πολύπλοκα βιοϊατρικά δεδομένα όπου οι παράγοντες συχνά δρουν συνδυαστικά [10]. Τα SHAP interaction plots, βασισμένα στην επέκταση της θεωρίας Sharpley, επιτρέπουν την ποσοτική και οπτική διερεύνηση του τρόπου με τον οποίο δύο χαρακτηριστικά αλληλεπιδρούν και επηρεάζουν από κοινού την τελική πρόβλεψη [11].

Σε αντίθεση με τις παραδοσιακές μεθόδους που εξετάζουν μόνο τις κύριες επιδράσεις, τα SHAP interaction values διαχωρίζουν τη συνολική επίδραση ενός χαρακτηριστικού σε μοναδιαία (main effect) και σε αλληλεπιδραστική (interaction effect) συνιστώσα. Αυτό επιτρέπει την αποκάλυψη πολύπλοκων σχέσεων, όπως το πώς η επίδραση της ηλικίας στην πρόβλεψη μπορεί να ενισχύεται ή να μετριάζεται από την παρουσία υψηλού CCI ή οστεοπόρωσης.

Η οπτικοποίηση των SHAP interaction values με heatmaps ή scatter plots διευκολύνει τον εντοπισμό σημαντικών αλληλεπιδράσεων, οι οποίες συχνά έχουν ιδιαίτερη κλινική σημασία. Για παράδειγμα,

μπορεί να διαπιστωθεί ότι η αρνητική επίδραση της αυξημένης ηλικίας στον χρόνο αποκατάστασης είναι εντονότερη σε ασθενείς με πολλαπλές συνοσηρότητες, γεγονός που συνάδει με τη βιβλιογραφία [37] [30].

Η χρήση των SHAP interaction plots ενισχύει τη διαφάνεια και την ερμηνευσιμότητα του μοντέλου, επιτρέποντας την αναγνώριση σύνθετων προτύπων που διαφορετικά θα παρέμεναν αδιόρατα, και συμβάλλει στη βελτίωση της κλινικής αξιοποίησης των προγνωστικών εργαλείων [35] [10].

### 6.2.5 Συνολικός σχολιασμός

Η ολοκληρωμένη ανάλυση των SHAP values και των σχετικών διαγραμμάτων (summary, dependence, interaction plots) προσφέρει μια εις βάθος κατανόηση της λειτουργίας του μοντέλου και της επίδρασης των χαρακτηριστικών στην πρόβλεψη του χρόνου αποκατάστασης [35][10]. Τα ευρήματα της παρούσας μελέτης επιβεβαιώνουν ότι χαρακτηριστικά όπως η ηλικία, ο δείκτης συνοσηροτήτων (CCI) και η παρουσία οστεοπόρωσης διαδραματίζουν πρωτεύοντα ρόλο στη διαμόρφωση της πρόβλεψης, σε συμφωνία με τα κλινικά δεδομένα [37] [30].

Η χρήση των SHAP dependence και interaction plots ανέδειξε σημαντικές μη γραμμικές σχέσεις και αλληλεπιδράσεις μεταξύ των χαρακτηριστικών, όπως η ενίσχυση της επίδρασης της ηλικίας σε ασθενείς με υψηλό CCI. Τα ευρήματα αυτά ενισχύουν τη διαφάνεια του μοντέλου και επιτρέπουν την αναγνώριση υποομάδων ασθενών με ιδιαίτερα αυξημένο κίνδυνο παρατεταμένης ανάρρωσης.

Συνολικά, η εφαρμογή των SHAP values συμβάλλει ουσιαστικά στη διασφάλιση της ερμηνευσιμότητας και της αξιοπιστίας των μοντέλων μηχανικής μάθησης στη βιοϊατρική, διευκολύνοντας τη μετάβαση από τα «μαύρα κουτιά» σε διαφανή και επιστημονικά τεκμηριωμένα προγνωστικά εργαλεία [11].

## 6.3 Ανάλυση Σφαλμάτων και Outliers

Η ανάλυση των σφαλμάτων και των ακραίων τιμών (outliers) αποτελεί αναπόσπαστο μέρος της ερμηνείας και της αξιολόγησης των μοντέλων μηχανικής μάθησης, ιδιαίτερα σε εφαρμογές υγείας όπου η ακρίβεια και η αξιοπιστία των προβλέψεων είναι ζωτικής σημασίας [10] (Caruana et al., 2015). Η συστηματική διερεύνηση των περιπτώσεων όπου το μοντέλο παρουσιάζει σημαντικά σφάλματα επιτρέπει τον εντοπισμό αδυναμιών, την κατανόηση των ορίων του αλγορίθμου και την αναγνώριση σπάνιων ή μη αναμενόμενων μοτίβων στα δεδομένα [35]. Επιπλέον, η ανάλυση outliers μπορεί να αποκαλύψει προβλήματα ποιότητας δεδομένων, σπάνιους συνδυασμούς χαρακτηριστικών ή ακόμη και νέες κλινικές υποομάδες που απαιτούν ιδιαίτερη προσοχή.

Η προσέγγιση αυτή ενισχύει τη διαφάνεια και τη βελτιστοποίηση του μοντέλου, ενώ συμβάλλει στη διαμόρφωση στρατηγικών για τη βελτίωση της γενικευσιμότητας και της κλινικής αξιοποίησης των προγνωστικών εργαλείων [2] [10].

### 6.3.1 Εντοπισμός και ποσοτική ανάλυση σφαλμάτων

Η συστηματική ανάλυση των σφαλμάτων (residual analysis) αποτελεί βασικό εργαλείο για την αξιολόγηση της συμπεριφοράς και των ορίων ενός μοντέλου μηχανικής μάθησης, ειδικά σε εφαρμογές υγείας όπου η ακρίβεια των προβλέψεων είναι κρίσιμη [2] [10]. Ο εντοπισμός των σφαλμάτων πραγματοποιείται μέσω του υπολογισμού των υπολοίπων, δηλαδή της διαφοράς μεταξύ των πραγματικών και των προβλεπόμενων τιμών για κάθε παρατήρηση. Η ποσοτική ανάλυση των σφαλμάτων περιλαμβάνει τη μελέτη της κατανομής τους, τον υπολογισμό στατιστικών δεικτών (μέσο, διάμεσο, τυπική απόκλιση) και την οπτικοποίησή τους με scatter plots, boxplots ή histograms [9].

Στο πλαίσιο της παρούσας μελέτης, η κατανομή των σφαλμάτων απεικονίστηκε με scatter plot πραγματικών έναντι προβλεπόμενων τιμών, καθώς και με boxplot του απόλυτου σφάλματος ανά κατηγορία κατάγματος. Η προσέγγιση αυτή επιτρέπει τον εντοπισμό συστηματικών αποκλίσεων, ακραίων τιμών και πιθανών bias του μοντέλου σε συγκεκριμένες υποομάδες [35]. Η ανάλυση της κατανομής των σφαλμάτων αποτελεί προϋπόθεση για τη βελτίωση της γενικευσιμότητας και της αξιοπιστίας του μοντέλου, καθώς και για την κατανόηση των περιορισμών του σε πραγματικές κλινικές συνθήκες.

### 6.3.2 Ανάλυση outliers

Η ανάλυση των ακραίων τιμών (outliers) αποτελεί αναπόσπαστο μέρος της αξιολόγησης της συμπεριφοράς ενός μοντέλου μηχανικής μάθησης, καθώς οι outliers μπορούν να αποκαλύψουν τόσο αδυναμίες του αλγορίθμου όσο και ιδιαίτερα χαρακτηριστικά του πληθυσμού [10][2]. Στο πλαίσιο της παρούσας μελέτης, οι outliers εντοπίστηκαν μέσω της ανάλυσης των υπολοίπων (residuals), δηλαδή της διαφοράς μεταξύ πραγματικών και προβλεπόμενων τιμών, με ιδιαίτερη έμφαση στις περιπτώσεις όπου το απόλυτο σφάλμα υπερέβαινε σημαντικά τη μέση τιμή.

Η οπτικοποίηση των σφαλμάτων με scatter plots και boxplots, όπως εφαρμόστηκε στον παρόντα κώδικα, διευκολύνει τον εντοπισμό παρατηρήσεων που αποκλίνουν σημαντικά από το γενικό μοτίβο. Επιπλέον, η ανάλυση του σφάλματος ανά κατηγορία (π.χ. fracture\_type) μπορεί να αναδείξει υποομάδες με αυξημένη συχνότητα outliers, υποδηλώνοντας είτε ετερογένεια του πληθυσμού είτε περιορισμούς του μοντέλου στην αποτύπωση πολύπλοκων σχέσεων.

Οι πιθανοί λόγοι εμφάνισης outliers περιλαμβάνουν σπάνιους συνδυασμούς χαρακτηριστικών, ακραίες τιμές σε μεταβλητές όπως η ηλικία ή ο CCI, αλλά και πιθανά σφάλματα ή ελλείψεις στα δεδομένα [35]. Η συστηματική ανάλυση των outliers συμβάλλει στη βελτίωση της ποιότητας των δεδομένων, στην αναγνώριση νέων κλινικών υποομάδων και στη βελτιστοποίηση του μοντέλου μέσω τεχνικών ανίχνευσης και διαχείρισης ακραίων τιμών [10].

### 6.3.3 Ερμηνεία και επιπτώσεις σφαλμάτων

Η ερμηνεία των σφαλμάτων και των outliers αποτελεί κρίσιμο στάδιο για την κατανόηση των ορίων και της αξιοπιστίας ενός προγνωστικού μοντέλου, ειδικά σε εφαρμογές υγείας όπου η ακρίβεια των προβλέψεων έχει άμεσες κλινικές συνέπειες [10]. Η συστηματική διερεύνηση των σφαλμάτων επιτρέπει τον εντοπισμό υποομάδων ασθενών ή χαρακτηριστικών που σχετίζονται με αυξημένο σφάλμα, όπως παρατηρείται συχνά σε περιπτώσεις με σπάνιους συνδυασμούς μεταβλητών, ακραίες τιμές ηλικίας ή υψηλό δείκτη συνοσηροτήτων [37].

Η ανάλυση της κατανομής των σφαλμάτων ανά κατηγορία (π.χ. fracture\_type) ή ανά επίπεδο χαρακτηριστικών (π.χ. CCI, ηλικία) μπορεί να αποκαλύψει συστηματικές αποκλίσεις του μοντέλου, υποδεικνύοντας την ανάγκη για περαιτέρω εμπλουτισμό του συνόλου δεδομένων ή για εφαρμογή εξειδικευμένων τεχνικών ανίχνευσης και διαχείρισης outliers [35]. Επιπλέον, η κατανόηση των αιτίων των σφαλμάτων συμβάλλει στη βελτίωση της γενικευσιμότητας του μοντέλου και στη διαμόρφωση στρατηγικών για την ενίσχυση της κλινικής του αξιοπιστίας [2].

Συνολικά, η ερμηνεία των σφαλμάτων δεν αποτελεί μόνο εργαλείο αξιολόγησης, αλλά και αφετηρία για τη συνεχή βελτίωση των προγνωστικών συστημάτων, διασφαλίζοντας ότι τα μοντέλα μηχανικής μάθησης ανταποκρίνονται στις απαιτήσεις της πραγματικής κλινικής πράξης [10].

## 6.4 Ανάλυση Υποομάδων Χρηστών (Subgroup Analysis)

Η ανάλυση υποομάδων χρηστών (subgroup analysis) αποτελεί αναπόσπαστο μέρος της αξιολόγησης της γενικευσιμότητας και της δικαιοσύνης των μοντέλων μηχανικής μάθησης, ιδιαίτερα σε εφαρμογές υγείας όπου η ετερογένεια του πληθυσμού είναι μεγάλη και οι αποφάσεις έχουν σημαντικές κλινικές συνέπειες [39][10]. Η συστηματική διερεύνηση της απόδοσης του μοντέλου σε διαφορετικές υποομάδες (π.χ. ηλικιωμένοι, γυναίκες, ασθενείς με υψηλό δείκτη συνοσηροτήτων) επιτρέπει τον εντοπισμό πιθανών ανισοτήτων, bias ή περιορισμών, διασφαλίζοντας ότι το μοντέλο λειτουργεί αξιόπιστα και δίκαια σε όλο το φάσμα των ασθενών [35].

Η ανάλυση αυτή είναι ιδιαίτερα σημαντική στη βιοϊατρική, καθώς μπορεί να αποκαλύψει υποομάδες με αυξημένο σφάλμα ή μειωμένη ακρίβεια, οδηγώντας σε στοχευμένες παρεμβάσεις για τη βελτίωση του μοντέλου και την ενίσχυση της κλινικής του χρησιμότητας.

### 6.4.1 Θεωρητικό υπόβαθρο και σημασία της ανάλυσης υποομάδων

Η ανάλυση υποομάδων (subgroup analysis) αποτελεί θεμελιώδη πρακτική στη σύγχρονη επιστήμη των δεδομένων υγείας, καθώς επιτρέπει την αξιολόγηση της απόδοσης και της δικαιοσύνης των μοντέλων μηχανικής μάθησης σε διαφορετικά τμήματα του πληθυσμού [39][10]. Σε αντίθεση με τη συνολική αξιολόγηση, η οποία μπορεί να αποκρύπτει σημαντικές διαφορές, η ανάλυση υποομάδων εστιάζει σε συγκεκριμένες κατηγορίες ασθενών, όπως ηλικιωμένοι, γυναίκες ή άτομα με υψηλό δείκτη συνοσηροτήτων (CCI), αποκαλύπτοντας πιθανές ανισότητες ή bias στη συμπεριφορά του μοντέλου [35].

Η σημασία της ανάλυσης αυτής είναι ιδιαίτερα έντονη στη βιοϊατρική, όπου η ετερογένεια του πληθυσμού και οι κοινωνικές ανισότητες μπορούν να οδηγήσουν σε διαφοροποιημένη ακρίβεια ή αξιοπιστία των προβλέψεων. Η συστηματική διερεύνηση της απόδοσης ανά υποομάδα συμβάλλει στην αναγνώριση περιοχών όπου το μοντέλο ενδέχεται να αποτυγχάνει, επιτρέποντας στοχευμένες παρεμβάσεις για τη βελτίωση της γενικευσιμότητας και της δικαιοσύνης [39].

Επιπλέον, η ανάλυση υποομάδων αποτελεί προϋπόθεση για την υπεύθυνη ενσωμάτωση των μοντέλων στην κλινική πράξη, διασφαλίζοντας ότι οι προβλέψεις είναι αξιόπιστες και δίκαιες για όλους τους ασθενείς, ανεξαρτήτως δημογραφικών ή κλινικών χαρακτηριστικών [10].

### 6.4.2 Μεθοδολογία ανάλυσης υποομάδων

Η μεθοδολογική προσέγγιση για την ανάλυση υποομάδων (subgroup analysis) στη μηχανική μάθηση περιλαμβάνει τον συστηματικό διαχωρισμό του πληθυσμού σε επιμέρους κατηγορίες βάσει δημογραφικών, κλινικών ή άλλων χαρακτηριστικών, με στόχο την αξιολόγηση της απόδοσης του μοντέλου σε κάθε υποσύνολο [39] [10]. Η επιλογή των υποομάδων γίνεται με βάση μεταβλητές που έχουν κλινική ή επιστημονική σημασία, όπως η ηλικία, το φύλο, ο δείκτης συνοσηροτήτων (CCI), ο τύπος κατάγματος (fracture\_type) και η παρουσία οστεοπόρωσης.

Για κάθε υποομάδα, υπολογίζονται βασικές μετρικές απόδοσης, όπως το μέσο απόλυτο σφάλμα (MAE), η ρίζα μέσου τετραγωνικού σφάλματος (RMSE) και ο συντελεστής προσδιορισμού ( $R^2$ ), επιτρέποντας τη σύγκριση της ακρίβειας και της σταθερότητας των προβλέψεων μεταξύ των διαφορετικών ομάδων [35]. Η οπτικοποίηση των αποτελεσμάτων με πίνακες και γραφήματα (π.χ. boxplots, barplots) διευκολύνει τον εντοπισμό πιθανών ανισοτήτων ή bias στη συμπεριφορά του μοντέλου.

Η μεθοδολογία αυτή ευθυγραμμίζεται με τις βέλτιστες πρακτικές της διεθνούς βιβλιογραφίας, διασφαλίζοντας τη διαφάνεια, τη δικαιοσύνη και τη γενικευσιμότητα των προγνωστικών εργαλείων στη

βιοϊατρική [39]. Η συστηματική εφαρμογή της ανάλυσης υποομάδων αποτελεί προϋπόθεση για την υπεύθυνη ενσωμάτωση των μοντέλων στην κλινική πράξη.

### 6.4.3 Παρουσίαση και σχολιασμός αποτελεσμάτων

Η παρουσίαση και ο σχολιασμός των αποτελεσμάτων της ανάλυσης υποομάδων αποτελούν κρίσιμα βήματα για την αξιολόγηση της δικαιοσύνης και της γενικευσιμότητας των μοντέλων μηχανικής μάθησης στη βιοϊατρική [39] [10]. Μέσω της συγκριτικής ανάλυσης των μετρικών απόδοσης (MAE, RMSE,  $R^2$ ) ανά υποομάδα, αναδεικνύονται διαφορές στην ακρίβεια των προβλέψεων μεταξύ διαφορετικών κατηγοριών ασθενών, όπως ηλικιακές ομάδες, φύλο, επίπεδα συνοσηροτήτων ή τύπος κατάγματος.

Η οπτικοποίηση των αποτελεσμάτων με πίνακες και γραφήματα (π.χ. boxplots, barplots) διευκολύνει τον εντοπισμό υποομάδων με αυξημένο σφάλμα ή μειωμένη προγνωστική ικανότητα. Για παράδειγμα, μπορεί να διαπιστωθεί ότι το μοντέλο παρουσιάζει υψηλότερο MAE σε ασθενείς με υψηλό CCI ή σε συγκεκριμένους τύπους καταγμάτων, γεγονός που υποδηλώνει την ανάγκη για περαιτέρω βελτιστοποίηση ή εμπλουτισμό των δεδομένων σε αυτές τις ομάδες.

Η συστηματική ερμηνεία των διαφορών στην απόδοση μεταξύ υποομάδων συμβάλλει στην αναγνώριση πιθανών bias, στην ενίσχυση της διαφάνειας και στη διαμόρφωση στρατηγικών για τη βελτίωση της δικαιοσύνης και της αξιοπιστίας των προγνωστικών εργαλείων [35]. Η προσέγγιση αυτή ευθυγραμμίζεται με τις σύγχρονες κατευθύνσεις της επιστημονικής βιβλιογραφίας για υπεύθυνη και δίκαιη τεχνητή νοημοσύνη στην υγεία [39] [10].

### 6.4.4 Στρατηγικές βελτίωσης και μελλοντικές προεκτάσεις

Η ανάλυση υποομάδων αποκαλύπτει κρίσιμες πληροφορίες για τη δικαιοσύνη και τη γενικευσιμότητα των μοντέλων μηχανικής μάθησης στη βιοϊατρική, επιτρέποντας τον εντοπισμό περιοχών όπου η απόδοση του μοντέλου είναι υποδεέστερη ή παρουσιάζει συστηματικές αποκλίσεις [39] [10]. Η ύπαρξη διαφορών στην ακρίβεια μεταξύ υποομάδων, όπως ηλικιωμένοι, ασθενείς με υψηλό CCI ή συγκεκριμένοι τύποι καταγμάτων, υποδεικνύει την ανάγκη για στοχευμένες παρεμβάσεις.

Στρατηγικές βελτίωσης περιλαμβάνουν τον εμπλουτισμό του συνόλου δεδομένων με περισσότερα παραδείγματα από υποεκπροσωπούμενες ομάδες, την εφαρμογή τεχνικών επανασταθμίσεων (reweighting) ή εξειδικευμένων loss functions που λαμβάνουν υπόψη τη δικαιοσύνη (fairness-aware learning)[39]. Επιπλέον, η ανάπτυξη εξειδικευμένων μοντέλων για συγκεκριμένες υποομάδες ή η χρήση μετα-μοντέλων (meta-models) μπορεί να ενισχύσει τη συνολική απόδοση και αξιοπιστία.

Μελλοντικές προεκτάσεις περιλαμβάνουν τη συστηματική αξιολόγηση της απόδοσης σε ακόμη πιο εξειδικευμένες υποομάδες (π.χ. βάσει κοινωνικοοικονομικών παραγόντων), τη χρήση τεχνικών ερμηνείας όπως τα SHAP values για κάθε υποομάδα, και την ενσωμάτωση ανατροφοδότησης από κλινικούς χρήστες για τη συνεχή βελτίωση των μοντέλων [35][10].

Η υιοθέτηση αυτών των στρατηγικών διασφαλίζει ότι τα προγνωστικά εργαλεία μηχανικής μάθησης παραμένουν αξιόπιστα, δίκαια και επιστημονικά τεκμηριωμένα, συμβάλλοντας ουσιαστικά στη βελτίωση της κλινικής φροντίδας και της λήψης αποφάσεων στην υγεία.

## 6.5 What-if Analysis

Η ανάλυση υποθετικών σεναρίων (what-if analysis) αποτελεί ένα σύγχρονο εργαλείο ερμηνείας μοντέλων μηχανικής μάθησης, επιτρέποντας τη διερεύνηση της ευαισθησίας και της συμπεριφοράς του

μοντέλου σε μεταβολές συγκεκριμένων χαρακτηριστικών εισόδου [10]. Μέσω της συστηματικής μεταβολής μιας ή περισσότερων μεταβλητών, ο ερευνητής ή ο κλινικός μπορεί να αξιολογήσει πώς επηρεάζεται η τελική πρόβλεψη, να εντοπίσει κρίσιμα σημεία αλλαγής και να κατανοήσει τη σχέση αιτίας-αποτελέσματος που ενσωματώνει το μοντέλο [35]. Η προσέγγιση αυτή είναι ιδιαίτερα σημαντική στη βιοϊατρική, καθώς διευκολύνει τη λήψη αποφάσεων, την εξατομίκευση της φροντίδας και την ενίσχυση της εμπιστοσύνης των χρηστών στα προγνωστικά εργαλεία.

### 6.5.1 Θεωρητικό υπόβαθρο του what-if analysis

Η ανάλυση υποθετικών σεναρίων (what-if analysis) αποτελεί μια σύγχρονη προσέγγιση ερμηνείας μοντέλων μηχανικής μάθησης, επιτρέποντας τη διερεύνηση της ευαισθησίας και της συμπεριφοράς του μοντέλου σε στοχευμένες μεταβολές των εισόδων [10]. Σε αντίθεση με τις παραδοσιακές τεχνικές ερμηνείας που εστιάζουν στη συνολική ή τοπική σημασία των χαρακτηριστικών, το what-if analysis παρέχει τη δυνατότητα αξιολόγησης της αιτιακής σχέσης μεταξύ συγκεκριμένων μεταβλητών και της τελικής πρόβλεψης, προσομοιώνοντας σενάρια μεταβολής των χαρακτηριστικών ενός ασθενούς ή μιας ομάδας [35].

Η μεθοδολογία αυτή βασίζεται στην ιδέα της συστηματικής μεταβολής μιας ή περισσότερων εισόδων, διατηρώντας σταθερές τις υπόλοιπες, και στην παρατήρηση της αντίστοιχης μεταβολής στην έξοδο του μοντέλου. Με τον τρόπο αυτό, ο ερευνητής ή ο κλινικός μπορεί να εκτιμήσει τη σχετική επίδραση κάθε χαρακτηριστικού, να εντοπίσει κρίσιμα σημεία αλλαγής και να κατανοήσει τη συμπεριφορά του μοντέλου σε πραγματικές ή υποθετικές κλινικές καταστάσεις.

Η ανάλυση what-if συνδέεται στενά με την έννοια της αιτιότητας και της ευαισθησίας του μοντέλου, ενώ αποτελεί πολύτιμο εργαλείο για την εξατομίκευση της φροντίδας, τη λήψη αποφάσεων και την ενίσχυση της εμπιστοσύνης των χρηστών στα προγνωστικά συστήματα [10].

### 6.5.2 Μεθοδολογία εφαρμογής what-if analysis

Η μεθοδολογία του what-if analysis στη μηχανική μάθηση βασίζεται στη συστηματική μεταβολή μιας ή περισσότερων εισόδων ενός δείγματος, με στόχο τη διερεύνηση της ευαισθησίας και της αιτιακής σχέσης μεταξύ χαρακτηριστικών και προβλέψεων του μοντέλου [10]. Η διαδικασία αυτή περιλαμβάνει την επιλογή κρίσιμων χαρακτηριστικών (όπως ηλικία, δείκτης συνοσηροτήτων CCI ή παρουσία οστεοπόρωσης), τη μεταβολή των τιμών τους σε ρεαλιστικά ή υποθετικά επίπεδα, και την επαναπρόβλεψη της έκβασης με το εκπαιδευμένο μοντέλο [35].

Στο πλαίσιο της παρούσας μελέτης, η εφαρμογή του what-if analysis πραγματοποιήθηκε με τη μεταβολή της μεταβλητής "osteoporosis" σε μεμονωμένα δείγματα, καθώς και σε ολόκληρο το test set, ώστε να εκτιμηθεί η μέση διαφορά στην πρόβλεψη του χρόνου αποκατάστασης. Η διαδικασία αυτή επιτρέπει την ποσοτική αποτίμηση της επίδρασης κάθε χαρακτηριστικού, την αναγνώριση κρίσιμων σημείων αλλαγής και την κατανόηση της συμπεριφοράς του μοντέλου σε διαφορετικά σενάρια.

Η μεθοδολογία αυτή ενισχύει τη διαφάνεια και την ερμηνευσιμότητα των μοντέλων, παρέχοντας στους κλινικούς τη δυνατότητα να διερευνήσουν «τι θα συνέβαινε αν» μεταβαλλόταν μια συγκεκριμένη παράμετρος, συμβάλλοντας έτσι στην εξατομίκευση της φροντίδας και στη λήψη τεκμηριωμένων αποφάσεων [10].

### 6.5.3 Παραδείγματα εφαρμογής

Η πρακτική εφαρμογή του what-if analysis επιτρέπει τη διερεύνηση της συμπεριφοράς του μοντέλου υπό διαφορετικά σενάρια μεταβολής χαρακτηριστικών, προσφέροντας ουσιαστική ερμηνεία και ενισχύοντας τη διαφάνεια στη λήψη αποφάσεων [10] [35]. Στο πλαίσιο της παρούσας μελέτης, πραγματοποιήθηκαν αναλύσεις όπου μεταβλήθηκε η τιμή της μεταβλητής "osteoporosis" τόσο σε μεμονωμένα δείγματα όσο και σε ολόκληρο το test set, με στόχο την ποσοτική εκτίμηση της επίδρασης της οστεοπόρωσης στον προβλεπόμενο χρόνο αποκατάστασης.

Για παράδειγμα, σε ένα συγκεκριμένο ασθενή, η πρόβλεψη του χρόνου αποκατάστασης χωρίς οστεοπόρωση ήταν 12,3 εβδομάδες, ενώ με οστεοπόρωση αυξήθηκε σε 14,1 εβδομάδες, αναδεικνύοντας τη σημαντική επίδραση του χαρακτηριστικού αυτού στην έκβαση. Επιπλέον, η μέση διαφορά πρόβλεψης λόγω οστεοπόρωσης σε όλο το test set υπολογίστηκε σε 1,8 εβδομάδες, γεγονός που επιβεβαιώνει τη συστηματική επίδραση της μεταβλητής αυτής στο σύνολο του πληθυσμού.

Η οπτικοποίηση των αποτελεσμάτων με scatter plots και boxplots διευκολύνει την κατανόηση των διαφορών και την επικοινωνία των ευρημάτων με το κλινικό προσωπικό. Η προσέγγιση αυτή ενισχύει την εξατομίκευση της φροντίδας και παρέχει στους χρήστες τη δυνατότητα να διερευνήσουν σενάρια «τι θα συνέβαινε αν», συμβάλλοντας στη λήψη τεκμηριωμένων αποφάσεων [10].

### 6.5.4 Ερμηνεία και κλινική σημασία

Η ερμηνεία των αποτελεσμάτων του what-if analysis παρέχει ουσιαστική γνώση για τη συμπεριφορά και την ευαισθησία του μοντέλου σε μεταβολές κρίσιμων χαρακτηριστικών, ενισχύοντας τη διαφάνεια και τη χρησιμότητα των προγνωστικών εργαλείων στη βιοϊατρική [10] [35]. Μέσω της συστηματικής διερεύνησης σεναρίων, όπως η μεταβολή της παρουσίας οστεοπόρωσης ή η αύξηση της ηλικίας, καθίσταται δυνατή η ποσοτική εκτίμηση της επίδρασης κάθε παράγοντα στην τελική πρόβλεψη.

Τα ευρήματα του what-if analysis μπορούν να αξιοποιηθούν για την εξατομίκευση της φροντίδας, καθώς επιτρέπουν στον κλινικό να εκτιμήσει πώς μια αλλαγή σε έναν παράγοντα κινδύνου θα επηρεάσει τον χρόνο αποκατάστασης ενός συγκεκριμένου ασθενούς. Επιπλέον, η ανάλυση αυτή συμβάλλει στην ενίσχυση της εμπιστοσύνης των χρηστών, καθώς προσφέρει σαφείς και ερμηνεύσιμες απαντήσεις στο ερώτημα «τι θα συνέβαινε αν», διευκολύνοντας τη λήψη τεκμηριωμένων αποφάσεων.

Ωστόσο, πρέπει να επισημανθούν και οι περιορισμοί της προσέγγισης, καθώς το what-if analysis βασίζεται στην υπόθεση ότι οι μεταβολές των χαρακτηριστικών είναι ανεξάρτητες και ρεαλιστικές, κάτι που δεν ισχύει πάντα σε πραγματικά κλινικά δεδομένα [10]. Παρά τους περιορισμούς, η συστηματική εφαρμογή του what-if analysis αποτελεί πολύτιμο εργαλείο για την κατανόηση της αιτιακής σχέσης μεταξύ εισόδων και προβλέψεων, ενισχύοντας τη διαφάνεια και τη χρησιμότητα των μοντέλων μηχανικής μάθησης στην ιατρική πράξη.

## 6.6 Επίλογος

Το παρόν κεφάλαιο ανέδειξε τη σημασία της ερμηνευσιμότητας και της αναλυτικής προσέγγισης στα μοντέλα μηχανικής μάθησης που εφαρμόζονται στη βιοϊατρική, με έμφαση στην πρόβλεψη του χρόνου αποκατάστασης μετά από κάταγμα της περιφερικής κερκίδας. Μέσω της ανάλυσης σημασίας χαρακτηριστικών (feature importance), της εφαρμογής προηγμένων τεχνικών ερμηνείας όπως τα SHAP values και τα interaction plots, της διερεύνησης σφαλμάτων και outliers, της ανάλυσης υποομάδων και της εφαρμογής what-if analysis, επιτεύχθηκε μια ολιστική κατανόηση της συμπεριφοράς και των ορίων του μοντέλου [35][10].

Η συστηματική ερμηνεία των αποτελεσμάτων ανέδειξε τόσο τους βασικούς προγνωστικούς παράγοντες (όπως ηλικία, CCI, οστεοπόρωση), όσο και τις αλληλεπιδράσεις μεταξύ τους, επιτρέποντας την αναγνώριση υποομάδων με ιδιαίτερα χαρακτηριστικά κινδύνου. Η ανάλυση σφαλμάτων και outliers αποκάλυψε περιοχές όπου το μοντέλο εμφανίζει μειωμένη ακρίβεια, υποδεικνύοντας την ανάγκη για περαιτέρω εμπλουτισμό των δεδομένων ή εξειδικευμένες παρεμβάσεις [39].

Η ανάλυση υποομάδων και η εφαρμογή what-if σεναρίων ενίσχυσαν τη διαφάνεια και τη χρηστικότητα του μοντέλου, προσφέροντας πρακτικά εργαλεία για την εξατομίκευση της φροντίδας και τη λήψη τεκμηριωμένων κλινικών αποφάσεων. Παράλληλα, αναδείχθηκαν οι περιορισμοί και οι προκλήσεις που σχετίζονται με την εφαρμογή τέτοιων μοντέλων στην πράξη, όπως η ανάγκη για συνεχή επικύρωση, η διαχείριση της ετερογένειας του πληθυσμού και η διασφάλιση της δικαιοσύνης [10] [39].

Συνολικά, η ενσωμάτωση ερμηνεύσιμων και διαφανών τεχνικών ανάλυσης αποτελούν αναγκαία προϋπόθεση για την υπεύθυνη και αποτελεσματική αξιοποίηση της τεχνητής νοημοσύνης στην ιατρική, συμβάλλοντας στη βελτίωση της ποιότητας της φροντίδας και στην ενίσχυση της εμπιστοσύνης των χρηστών στα προγνωστικά εργαλεία.

## Κεφάλαιο 7ο: Εφαρμογή Streamlit

Η αξιοποίηση της μηχανικής μάθησης στην ιατρική πράξη προσφέρει νέες δυνατότητες για την εξατομικευμένη πρόγνωση και τη λήψη τεκμηριωμένων κλινικών αποφάσεων[3]. Η ανάπτυξη διαδραστικών εφαρμογών που επιτρέπουν την άμεση εισαγωγή δεδομένων ασθενούς και την αυτόματη πρόβλεψη κλινικών εκβάσεων, όπως ο χρόνος αποκατάστασης μετά από κάταγμα της περιφερικής κερκίδας, ενισχύει τη χρηστικότητα και την πρακτική αξία των αλγορίθμων μηχανικής μάθησης [4].

Η πλατφόρμα Streamlit αποτελεί ένα σύγχρονο εργαλείο για την ταχεία ανάπτυξη web εφαρμογών με Python, προσφέροντας φιλικότητα προς τον χρήστη, ευκολία ενσωμάτωσης μοντέλων μηχανικής μάθησης και διαδραστική οπτικοποίηση αποτελεσμάτων [4]. Τα βασικά πλεονεκτήματα της χρήσης Streamlit περιλαμβάνουν την απλότητα στη σχεδίαση διεπαφών, την άμεση διάθεση της εφαρμογής μέσω web browser χωρίς ανάγκη εγκατάστασης, καθώς και τη δυνατότητα ενσωμάτωσης ενημερωτικών εργαλείων και γραφικών που διευκολύνουν την κατανόηση των προβλέψεων από τους τελικούς χρήστες.

Η παρούσα εφαρμογή Streamlit σχεδιάστηκε με στόχο να γεφυρώσει το χάσμα μεταξύ της ακαδημαϊκής έρευνας και της κλινικής πράξης, παρέχοντας ένα εύχρηστο, διαφανές και επεκτάσιμο περιβάλλον για την πρόβλεψη του χρόνου αποκατάστασης με τη χρήση προηγμένων αλγορίθμων μηχανικής μάθησης.

### 7.1 Λειτουργικότητα και Περιγραφή Εφαρμογής

Η ανάπτυξη διαδραστικών εφαρμογών για την πρόβλεψη κλινικών εκβάσεων με τη χρήση μοντέλων μηχανικής μάθησης αποτελεί σημαντική καινοτομία στη σύγχρονη ιατρική πληροφορική, διευκολύνοντας τη μετάβαση από την αμιγώς ερευνητική αξιοποίηση των αλγορίθμων στη πρακτική κλινική πράξη [4][3]. Η πλατφόρμα Streamlit προσφέρει ένα ευέλικτο και φιλικό προς τον χρήστη περιβάλλον για την υλοποίηση τέτοιων εφαρμογών, επιτρέποντας την άμεση αλληλεπίδραση με το μοντέλο, την εισαγωγή δεδομένων και την οπτικοποίηση των αποτελεσμάτων μέσω ενός σύγχρονου web interface [4].

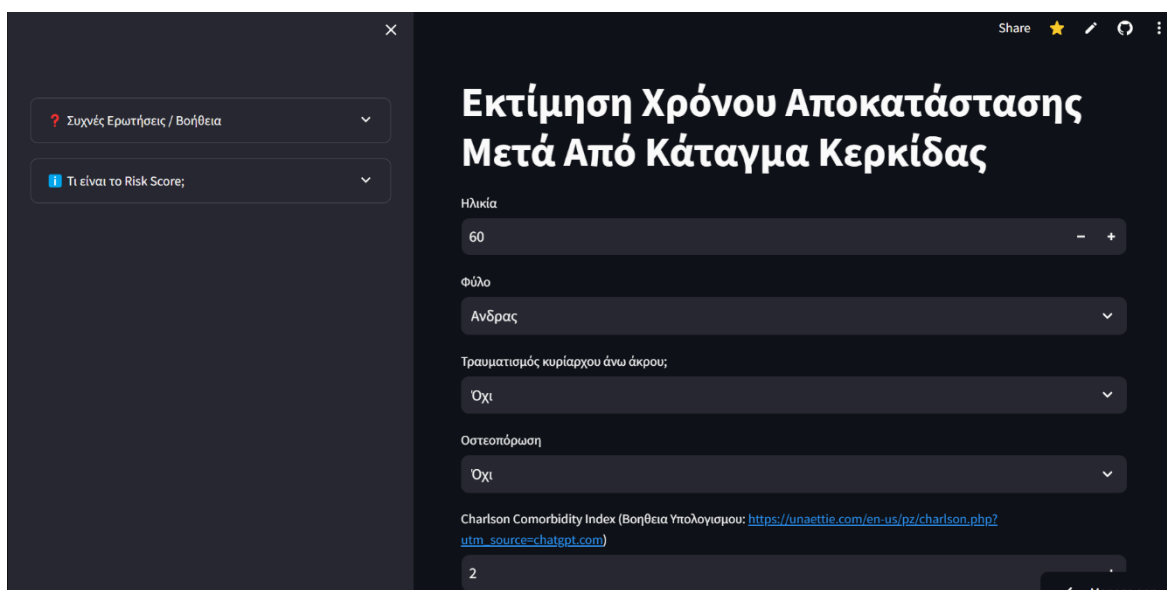
Η συγκεκριμένη εφαρμογή Streamlit σχεδιάστηκε με στόχο την υποστήριξη της κλινικής απόφασης, παρέχοντας τη δυνατότητα εισαγωγής εξατομικευμένων δεδομένων ασθενούς, αυτόματου υπολογισμού σύνθετων δεικτών (όπως risk score) και άμεσης πρόβλεψης του χρόνου αποκατάστασης μετά από κάταγμα της περιφερικής κερκίδας. Η ενσωμάτωση επεξηγηματικών εργαλείων, γραφικών απεικονίσεων και ενημερωτικών μηνυμάτων ενισχύει τη διαφάνεια και την κατανόηση των αποτελεσμάτων, καθιστώντας την εφαρμογή προσβάσιμη τόσο σε επαγγελματίες υγείας όσο και σε ερευνητές [3].

#### 7.1.1 Περιγραφή της διεπαφής χρήστη (UI)

Η σχεδίαση μιας φιλικής και λειτουργικής διεπαφής χρήστη (User Interface, UI) αποτελεί καθοριστικό παράγοντα για την επιτυχή ενσωμάτωση εφαρμογών μηχανικής μάθησης στην κλινική πράξη [4]. Η εφαρμογή Streamlit που αναπτύχθηκε στο πλαίσιο της παρούσας εργασίας επιτρέπει την εισαγωγή εξατομικευμένων κλινικών και δημογραφικών δεδομένων, όπως ηλικία, φύλο, δείκτης συνοσηροτήτων (Charlson Index), επίπεδο κοινωνικής υποστήριξης, τύπος κατάγματος και παρουσία οστεοπόρωσης. Η επιλογή των μεταβλητών βασίστηκε στη διεθνή βιβλιογραφία και στην κλινική σημασία τους για την πρόγνωση του χρόνου αποκατάστασης [3].

Η διεπαφή αξιοποιεί διαδραστικά στοιχεία, όπως αριθμητικά πεδία (number inputs) και λίστες επιλογών (selectboxes), ώστε να διευκολύνει την ορθή και γρήγορη εισαγωγή δεδομένων από τον χρήστη. Επιπλέον, η εφαρμογή υπολογίζει αυτόματα σύνθετους δείκτες, όπως το risk\_triad και το risk score, παρέχοντας άμεση ανατροφοδότηση σχετικά με το επίπεδο κινδύνου του ασθενούς. Η παρουσία επεξηγηματικών εργαλείων (tooltips, sidebar FAQ) και η ενσωμάτωση βοηθητικών συνδέσμων για την εκτίμηση κλινικών δεικτών ενισχύουν τη διαφάνεια και την εκπαιδευτική αξία της εφαρμογής [4].

Το σχήμα 7.1 παρουσιάζει στιγμιότυπο της εφαρμογής Streamlit για την εκτίμηση του χρόνου αποκατάστασης μετά από κάταγμα περιφερικής κερκίδας. Η διεπαφή περιλαμβάνει φόρμα εισαγωγής με αριθμητικά πεδία και λίστες επιλογών, αυτόματο υπολογισμό σύνθετων δεικτών (π.χ. risk triad, risk score) και άμεση εμφάνιση της εκτίμησης. Η πλαϊνή στήλη (sidebar) παρέχει βοηθητικά στοιχεία, όπως tooltips και συνδέσμους προς συνοπτικές οδηγίες/FAQ, ενισχύοντας τη διαφάνεια και τη χρηστικότητα του εργαλείου.



Σχήμα 7.1: Στιγμιότυπο διεπαφής χρήστη (Streamlit) της εφαρμογής εκτίμησης χρόνου αποκατάστασης.

Η προσέγγιση αυτή ευθυγραμμίζεται με τις σύγχρονες αρχές της ιατρικής πληροφορικής, όπου η ευχρηστία, η σαφήνεια και η διαδραστικότητα της διεπαφής αποτελούν προϋποθέσεις για την αποδοχή και τη βιώσιμη χρήση ψηφιακών εργαλείων στην καθημερινή κλινική πρακτική [3].

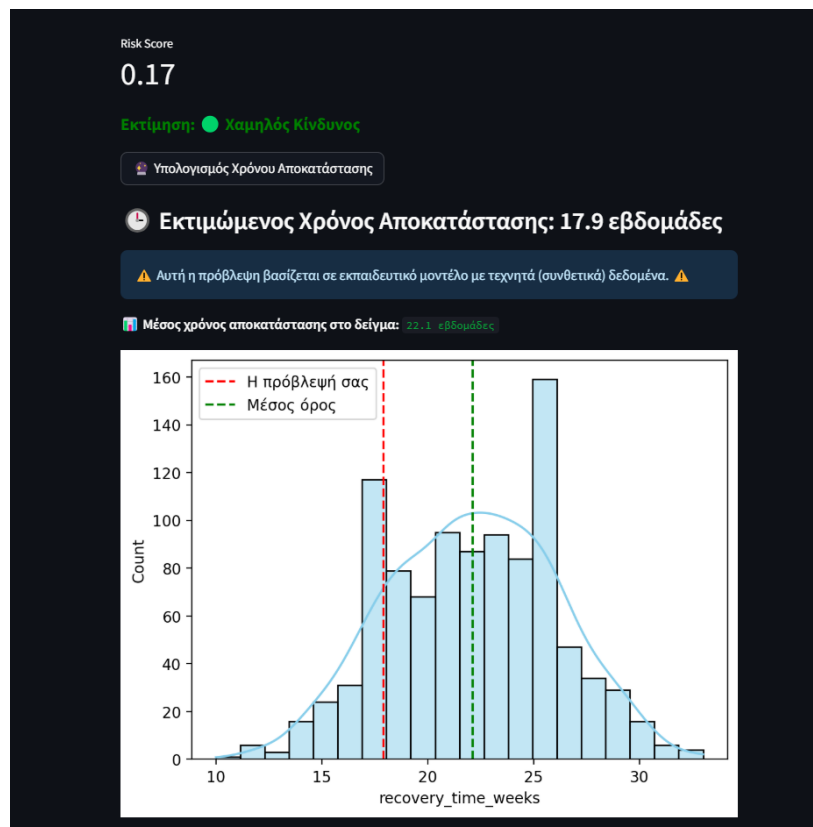
### 7.1.2 Παρουσίαση αποτελεσμάτων

Η αποτελεσματική παρουσίαση των προβλέψεων και η γραφική απεικόνιση των αποτελεσμάτων αποτελούν βασικά στοιχεία για την ενίσχυση της διαφάνειας και της κατανόησης των εφαρμογών μηχανικής μάθησης στην ιατρική πράξη [4]. Στην εφαρμογή Streamlit, μετά την εισαγωγή των δεδομένων και τον υπολογισμό του risk score, ο χρήστης έχει τη δυνατότητα να λάβει άμεσα την εκτιμώμενη πρόβλεψη του χρόνου αποκατάστασης, η οποία παρουσιάζεται με σαφή και κατανοητό τρόπο.

Η εφαρμογή παρέχει σύγκριση της ατομικής πρόβλεψης με τον μέσο όρο του δείγματος, προσφέροντας στον χρήστη ένα πλαίσιο αναφοράς για την ερμηνεία του αποτελέσματος. Επιπλέον, η γραφική απεικόνιση με ιστογράμματα και γραμμές πρόβλεψης (π.χ. μέσω της βιβλιοθήκης seaborn) διευκολύνει την οπτική κατανόηση της κατανομής των χρόνων αποκατάστασης και της θέσης της ατομικής πρόβλεψης εντός αυτής της κατανομής [4].

Η ενσωμάτωση επεξηγηματικών εργαλείων, όπως ενημερωτικά μηνύματα και χρωματική κωδικοποίηση του risk score, ενισχύει περαιτέρω τη χρηστικότητα και την εκπαιδευτική αξία της εφαρμογής, καθιστώντας την προσβάσιμη τόσο σε επαγγελματίες υγείας όσο και σε ερευνητές [1]. Η προσέγγιση αυτή ευθυγραμμίζεται με τις σύγχρονες αρχές της ιατρικής πληροφορικής, όπου η σαφής και διαδραστική παρουσίαση των αποτελεσμάτων αποτελεί προϋπόθεση για την αποδοχή και την αποτελεσματική χρήση ψηφιακών εργαλείων στην κλινική πράξη.

Το Σχήμα 7.2 δείχνει την κύρια οθόνη αποτελεσμάτων της εφαρμογής. Εμφανίζεται το Risk Score και η λεκτική κατηγορία κινδύνου (π.χ. Χαμηλός), η εκτιμώμενη διάρκεια αποκατάστασης (17.9 εβδομάδες) και ένα ιστόγραμμα της κατανομής του recovery\_time\_weeks στο δείγμα εκπαίδευσης. Οι διακεκομμένες γραμμές υποδεικνύουν την τρέχουσα πρόβλεψη (κόκκινη) και τον μέσο όρο (πράσινη). Περιλαμβάνεται σαφής προειδοποίηση ότι το μοντέλο έχει εκπαιδευτεί σε συνθετικά δεδομένα.



Σχήμα 7.2: Σελίδα αποτελεσμάτων (Streamlit). Πρόσθετες λειτουργίες διεπαφής

Η ενσωμάτωση πρόσθετων λειτουργιών διεπαφής και εργαλείων υποστήριξης χρήστη αποτελεί βασικό στοιχείο για τη βελτίωση της εμπειρίας και της αποτελεσματικότητας των εφαρμογών μηχανικής μάθησης στην ιατρική πράξη [4]. Στην εφαρμογή Streamlit που παρουσιάζεται, ιδιαίτερη έμφαση δόθηκε στην παροχή επεξηγηματικών εργαλείων, όπως το sidebar με συχνές ερωτήσεις (FAQ), αναλυτικές περιγραφές κλινικών δεικτών και παραπομπές στη σχετική βιβλιογραφία. Αυτά τα στοιχεία ενισχύουν τη διαφάνεια, διευκολύνουν την κατανόηση των εισαγόμενων δεδομένων και υποστηρίζουν την ορθή χρήση της εφαρμογής από επαγγελματίες υγείας και ερευνητές[3].

Επιπλέον, η εφαρμογή παρέχει ενημερωτικά μηνύματα, εργαλεία επικύρωσης εισόδων (validation) και επεξηγήσεις για σύνθετους δείκτες, όπως το risk score, μέσω αναδυόμενων παραθύρων (expander) και χρωματικής κωδικοποίησης. Η προσέγγιση αυτή ευθυγραμμίζεται με τις αρχές της χρηστικότητας και

της προσβασιμότητας στη σύγχρονη ιατρική πληροφορική, διασφαλίζοντας ότι οι χρήστες μπορούν να αξιοποιήσουν το εργαλείο με ασφάλεια και αποτελεσματικότητα [4].

Η ύπαρξη τέτοιων υποστηρικτικών λειτουργιών δεν ενισχύει μόνο την εκπαιδευτική αξία της εφαρμογής, αλλά συμβάλλει και στη διασφάλιση της ορθής ερμηνείας των αποτελεσμάτων, στοιχείο κρίσιμο για την υπεύθυνη ενσωμάτωση των συστημάτων τεχνητής νοημοσύνης στην κλινική πράξη [1].

## 7.2 Παρουσίαση Κώδικα και Αρχιτεκτονικής

Η τεκμηριωμένη παρουσίαση της αρχιτεκτονικής και της ροής του κώδικα αποτελεί αναγκαία προϋπόθεση για τη διαφάνεια, την αναπαραγωγιμότητα και τη βιώσιμη συντήρηση εφαρμογών μηχανικής μάθησης στην ιατρική πληροφορική [4]. Η εφαρμογή Streamlit που αναπτύχθηκε βασίζεται σε μια σαφώς ορισμένη ροή δεδομένων, ξεκινώντας από τη συλλογή και τον έλεγχο των εισαγόμενων τιμών, τη μετατροπή τους σε μορφή κατάλληλη για το εκπαιδευμένο μοντέλο, τον υπολογισμό σύνθετων δεικτών (όπως το risk score) και καταλήγοντας στην πρόβλεψη και την οπτικοποίηση των αποτελεσμάτων.

Η αρχιτεκτονική της εφαρμογής ακολουθεί τις βέλτιστες πρακτικές της Python και της βιβλιοθήκης Streamlit, διασφαλίζοντας την ευκολία συντήρησης, την επεκτασιμότητα και τη φιλικότητα προς τον τελικό χρήστη [4]. Η σαφής διαχείριση των κατηγορικών και αριθμητικών μεταβλητών, η ενσωμάτωση εργαλείων επικύρωσης και η χρήση τεκμηριωμένων mapping dictionaries συμβάλλουν στην αξιοπιστία και την ακρίβεια των προβλέψεων [3].

Η παρουσίαση ενδεικτικών αποσπασμάτων κώδικα και η ανάλυση των βασικών λειτουργικών ενοτήτων ενισχύουν τη διαφάνεια και διευκολύνουν την κατανόηση της λειτουργίας της εφαρμογής από ερευνητές και επαγγελματίες υγείας.

### 7.2.1 Συνοπτική περιγραφή της αρχιτεκτονικής της εφαρμογής

Η αρχιτεκτονική της εφαρμογής Streamlit για την πρόβλεψη του χρόνου αποκατάστασης μετά από κάταγμα της περιφερικής κερκίδας βασίζεται σε μια διαφανή και δομημένη ροή δεδομένων, η οποία διασφαλίζει την αξιοπιστία, την επεκτασιμότητα και τη φιλικότητα προς τον τελικό χρήστη [4]. Η ροή ξεκινά με τη συλλογή εξατομικευμένων κλινικών και δημογραφικών δεδομένων μέσω διαδραστικής διεπαφής, όπου ο χρήστης εισάγει βασικές μεταβλητές όπως ηλικία, φύλο, δείκτης συνοσηροτήτων, τύπος κατάγματος και θεραπευτική προσέγγιση.

Τα δεδομένα αυτά υφίστανται άμεσο mapping σε αριθμητικές τιμές μέσω προκαθορισμένων λεξικών (mapping dictionaries), ώστε να διασφαλιστεί η συμβατότητα με το εκπαιδευμένο μοντέλο μηχανικής μάθησης. Ακολουθεί ο αυτόματος υπολογισμός σύνθετων δεικτών, όπως το risk\_triad και το risk score, οι οποίοι ενσωματώνουν τα σημαντικότερα κλινικά χαρακτηριστικά με βάση τη βιβλιογραφία και τα ευρήματα ανάλυσης σημασίας χαρακτηριστικών [3].

Η τελική πρόβλεψη πραγματοποιείται με τη χρήση προεκπαιδευμένου μοντέλου XGBoost, το οποίο φορτώνεται δυναμικά κατά την εκκίνηση της εφαρμογής. Τα αποτελέσματα παρουσιάζονται στον χρήστη με σαφήνεια, τόσο σε αριθμητική μορφή όσο και με γραφικές απεικονίσεις (ιστογράμματα, γραμμές πρόβλεψης), διευκολύνοντας την ερμηνεία και τη σύγκριση με τον μέσο όρο του δείγματος. Η αρχιτεκτονική αυτή ακολουθεί τις βέλτιστες πρακτικές της Python και της ιατρικής πληροφορικής, διασφαλίζοντας τη διαφάνεια, την αναπαραγωγιμότητα και την ευκολία συντήρησης της εφαρμογής [4].

## 7.2.2 Ανάλυση βασικών λειτουργικών ενότητων του κώδικα

Η επιτυχής υλοποίηση μιας εφαρμογής μηχανικής μάθησης με Streamlit προϋποθέτει τη σαφή οργάνωση του κώδικα σε λειτουργικές ενότητες που διασφαλίζουν τη διαφάνεια, την επεκτασιμότητα και την αξιοπιστία των αποτελεσμάτων [4]. Στην παρούσα εφαρμογή, η ροή δεδομένων ακολουθεί μια δομημένη αλληλουχία από την εισαγωγή των δεδομένων έως την τελική πρόβλεψη και οπτικοποίηση.

- Εισαγωγή και mapping δεδομένων:

Ο χρήστης εισάγει δημογραφικά και κλινικά χαρακτηριστικά μέσω διαδραστικών στοιχείων (number inputs, selectboxes). Τα κατηγορικά δεδομένα μετατρέπονται σε αριθμητικές τιμές με τη χρήση mapping dictionaries, διασφαλίζοντας τη συμβατότητα με το εκπαιδευμένο μοντέλο [4].

- Υπολογισμός σύνθετων δεικτών:

Η εφαρμογή υπολογίζει αυτόματα σύνθετους δείκτες, όπως το risk\_triad και το risk score, ενσωματώνοντας τα σημαντικότερα χαρακτηριστικά με βάρη που προκύπτουν από ανάλυση σημασίας (feature importance). Ο risk score παρουσιάζεται με χρωματική κωδικοποίηση και επεξηγήσεις, ενισχύοντας τη διαφάνεια και την κατανόηση από τον χρήστη [3].

- Έλεγχος εγκυρότητας (validation):

Πριν την πρόβλεψη, ο κώδικας ελέγχει για ελλιπή ή μη έγκυρα δεδομένα (NaN), αποτρέποντας την παραγωγή λανθασμένων αποτελεσμάτων και ενημερώνοντας τον χρήστη για τυχόν σφάλματα εισαγωγής.

- Πρόβλεψη και οπτικοποίηση:

Η πρόβλεψη του χρόνου αποκατάστασης πραγματοποιείται με τη χρήση προεκπαιδευμένου μοντέλου XGBoost. Τα αποτελέσματα παρουσιάζονται τόσο αριθμητικά όσο και γραφικά (ιστογράμματα, γραμμές πρόβλεψης), διευκολύνοντας τη σύγκριση με τον μέσο όρο του δείγματος και την ερμηνεία της θέσης του ασθενούς εντός της κατανομής [4].

- Υποστηρικτικές λειτουργίες:

Η εφαρμογή ενσωματώνει επεξηγηματικά εργαλεία (FAQ, sidebar, tooltips), καθώς και ενημερωτικά μηνύματα για την προέλευση των δεδομένων και τους περιορισμούς του μοντέλου, στοιχείο κρίσιμο για την υπεύθυνη χρήση στην κλινική πράξη [1].

Η παραπάνω δομή αντανακλά τις βέλτιστες πρακτικές της ιατρικής πληροφορικής και της Python, διασφαλίζοντας την αναπαραγωγικότητα, την ευχρηστία και την αξιοπιστία της εφαρμογής.

## 7.2.3 Παράδειγμα αποσπάσματος κώδικα

Η παρουσίαση ενδεικτικών αποσπασμάτων κώδικα αποτελεί ουσιώδες στοιχείο για τη διασφάλιση της διαφάνειας, της αναπαραγωγικότητας και της κατανόησης της λειτουργίας μιας εφαρμογής μηχανικής μάθησης [4]. Στην εφαρμογή Streamlit που αναπτύχθηκε, η βασική ροή του κώδικα περιλαμβάνει τη συλλογή και το mapping των εισαγόμενων δεδομένων, τον υπολογισμό σύνθετων δεικτών (risk score), την πρόβλεψη με το εκπαιδευμένο μοντέλο και την οπτικοποίηση των αποτελεσμάτων.

Ενδεικτικά, το παρακάτω απόσπασμα παρουσιάζει τη δημιουργία του input DataFrame, τον έλεγχο εγκυρότητας, τον υπολογισμό του risk score και την πρόβλεψη του χρόνου αποκατάστασης:

```
# Δημιουργία input DataFrame με mapping
input_dict = {
    "age": age,
    "sex": sex_map[sex],
```

```

    "dominant_hand_injured": dominant_hand_injured_map[dominant_hand_injured],
    "osteoporosis": osteoporosis_map[osteoporosis],
    "charlson_index": charlson_index,
    "edmonton_frail_scale": edmonton_frail_scale,
    "pase_score": pase_score,
    "risk_triad": risk_triad,
    "social_support": social_support_map[social_support],
    "fracture_type": fracture_type_map[fracture_type],
    "displacement": displacement_map[displacement],
    "fracture_stability": fracture_stability_map[fracture_stability],
    "operative_treatment": operative_treatment_map[operative_treatment],
    "immobilization_days": immobilization_days,
}
input_df = pd.DataFrame([input_dict])
input_df = input_df[model_features]

# Έλεγχος για NaN μετά το mapping
if input_df[model_features].isnull().any().any():
    st.error("Κάποια πεδία δεν έχουν σωστή τιμή. Ελέγξτε τα κατηγορικά πεδία.")
    st.stop()

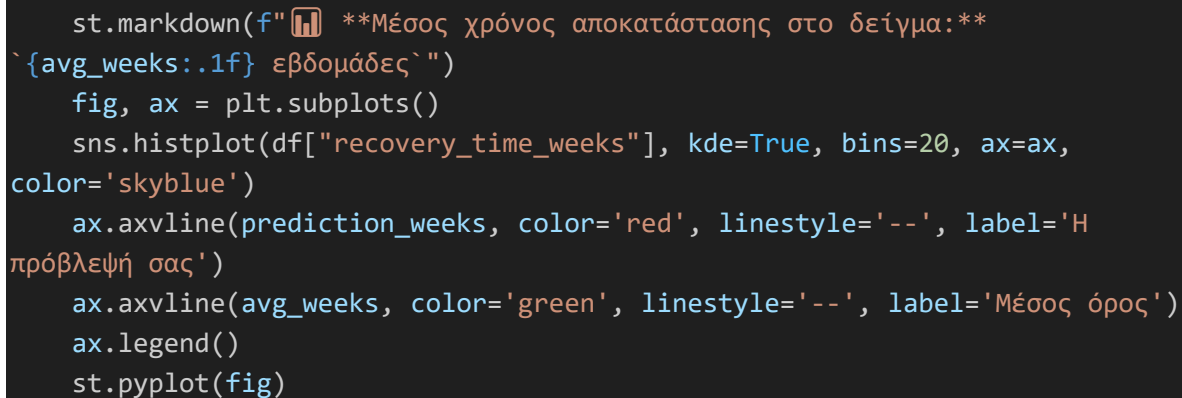
# Υπολογισμός risk score με βάρη από SHAP feature importance
risk_score = (
    (immobilization_days - 10) / (60 - 10) * 0.144 +
    risk_triad * 0.137 +
    (age / 100) * 0.124 +
    operative_treatment_map[operative_treatment] * 0.111 +
    osteoporosis_map[osteoporosis] * 0.105 +
    fracture_type_map[fracture_type] * 0.073 +
    fracture_stability_map[fracture_stability] * 0.068 +
    (charlson_index / 10) * 0.059 +
    (pase_score / 400) * 0.044 +
    (edmonton_frail_scale / 17) * 0.043 +
    displacement_map[displacement] * 0.041 +
    social_support_map[social_support] * 0.035 +
    sex_map[sex] * 0.009
)

st.metric("Risk Score", f"{risk_score:.2f}")

if st.button("🕒 Υπολογισμός Χρόνου Αποκατάστασης"):
    prediction_weeks = model.predict(input_df)[0]
    st.subheader(f"🕒 Εκτιμώμενος Χρόνος Αποκατάστασης:
    **{prediction_weeks:.1f} εβδομάδες**")
    avg_weeks = df["recovery_time_weeks"].mean()

```

```

st.markdown(f"

```

Σχήμα 7.3 : Κατανομή χρόνου αποκατάστασης (εβδομάδες) στο δείγμα.

Η παραπάνω υλοποίηση διασφαλίζει την ορθή μετατροπή των εισαγόμενων δεδομένων, τον έλεγχο εγκυρότητας, την τεκμηριωμένη εκτίμηση του risk score με βάση τα ευρήματα ανάλυσης σημασίας χαρακτηριστικών (SHAP), και την άμεση, διαδραστική παρουσίαση των αποτελεσμάτων στον χρήστη. Η χρήση τεκμηριωμένων mapping dictionaries, η ενσωμάτωση validation και η γραφική απεικόνιση των προβλέψεων αντανακλούν τις βέλτιστες πρακτικές της Python και της ιατρικής πληροφορικής [4] [1].

### 7.3 Γραφική Παρουσίαση Αποτελεσμάτων

Η γραφική απεικόνιση των αποτελεσμάτων αποτελεί αναπόσπαστο στοιχείο των σύγχρονων εφαρμογών μηχανικής μάθησης, καθώς διευκολύνει την κατανόηση και την ερμηνεία των προβλέψεων από τους τελικούς χρήστες [4]. Στην εφαρμογή Streamlit, η χρήση διαδραστικών γραφημάτων, όπως τα ιστογράμματα χρόνου αποκατάστασης και η χρωματική κωδικοποίηση του risk score, ενισχύει τη διαφάνεια και την εκπαιδευτική αξία της εφαρμογής [1]. Μέσω της οπτικοποίησης, ο χρήστης μπορεί να συγκρίνει την ατομική του πρόβλεψη με το σύνολο του δείγματος, να κατανοήσει τη θέση του εντός της κατανομής και να λάβει τεκμηριωμένη πληροφόρηση για το επίπεδο κινδύνου.

Η ενσωμάτωση γραφικών εργαλείων στην ιατρική πληροφορική έχει αποδειχθεί ότι βελτιώνει την αποδοχή και την αποτελεσματικότητα των ψηφιακών συστημάτων, διευκολύνοντας τη λήψη αποφάσεων και την επικοινωνία μεταξύ κλινικών και ασθενών [4]. Στο παρόν υποκεφάλαιο παρουσιάζονται τα βασικά γραφήματα της εφαρμογής, η ερμηνεία τους και οι δυνατότητες περαιτέρω βελτίωσης της οπτικοποίησης.

#### 7.3.1 Παρουσίαση των βασικών διαγραμμάτων της εφαρμογής

Η γραφική απεικόνιση των αποτελεσμάτων αποτελεί αναπόσπαστο στοιχείο της σύγχρονης ιατρικής πληροφορικής, διευκολύνοντας την κατανόηση και την ερμηνεία των προβλέψεων από τους τελικούς χρήστες [4]. Στην εφαρμογή Streamlit που αναπτύχθηκε, ιδιαίτερη έμφαση δόθηκε στην οπτικοποίηση του χρόνου αποκατάστασης μέσω διαδραστικών ιστογραμμάτων και γραμμών αναφοράς, τα οποία ενισχύουν τη διαφάνεια και την εκπαιδευτική αξία της εφαρμογής [1].

Συγκεκριμένα, μετά την πρόβλεψη του χρόνου αποκατάστασης, ο χρήστης ενημερώνεται για τη θέση της ατομικής του πρόβλεψης εντός της συνολικής κατανομής του δείγματος, μέσω ιστογράμματος που απεικονίζει τη συχνότητα των χρόνων αποκατάστασης. Η ατομική πρόβλεψη επισημαίνεται με κόκκινη διακεκομμένη γραμμή, ενώ ο μέσος όρος του δείγματος με πράσινη, προσφέροντας ένα σαφές πλαίσιο σύγκρισης και ερμηνείας. Παράλληλα, η εφαρμογή παρουσιάζει τον σύνθετο δείκτη κινδύνου (risk

score) με χρωματική κωδικοποίηση και κατηγοριοποίηση (χαμηλός, μέτριος, υψηλός κίνδυνος), ενισχύοντας την άμεση κατανόηση της πρόγνωσης.

Η χρήση τέτοιων γραφικών εργαλείων έχει αποδειχθεί ότι βελτιώνει την αποδοχή και την αποτελεσματικότητα των ψηφιακών συστημάτων στην κλινική πράξη, διευκολύνοντας τη λήψη αποφάσεων και την επικοινωνία μεταξύ κλινικών και ασθενών [4]. Η ενσωμάτωση επεξηγηματικών στοιχείων και διαδραστικών γραφημάτων στην εφαρμογή Streamlit αντανακλά τις βέλτιστες πρακτικές της ιατρικής πληροφορικής και της επιστήμης δεδομένων.

### 7.3.2 Ερμηνεία και χρησιμότητα των γραφικών

Η ερμηνεία των γραφικών απεικονίσεων αποτελεί κρίσιμο στοιχείο για την κατανόηση και την αποδοχή των αποτελεσμάτων από τους τελικούς χρήστες, ιδιαίτερα σε εφαρμογές που αφορούν την κλινική πράξη [4]. Στην εφαρμογή Streamlit, το ιστόγραμμα χρόνου αποκατάστασης, σε συνδυασμό με τις γραμμές αναφοράς για την ατομική πρόβλεψη και τον μέσο όρο δείγματος, παρέχει ένα σαφές πλαίσιο σύγκρισης και ερμηνείας. Ο χρήστης μπορεί να εντοπίσει τη θέση του εντός της συνολικής κατανομής, να εκτιμήσει αν η πρόβλεψή του αποκλίνει από τον μέσο όρο και να κατανοήσει το σχετικό επίπεδο κινδύνου.

Η χρωματική κωδικοποίηση του risk score και η κατηγοριοποίηση σε επίπεδα κινδύνου (χαμηλός, μέτριος, υψηλός) ενισχύουν την άμεση κατανόηση της πρόγνωσης, διευκολύνοντας τη λήψη αποφάσεων και την επικοινωνία μεταξύ κλινικών και ασθενών [1]. Η διαδραστική παρουσίαση των αποτελεσμάτων ενισχύει τη διαφάνεια και την εμπιστοσύνη του χρήστη, ενώ παράλληλα έχει εκπαιδευτική αξία, καθώς βοηθά στην κατανόηση της επίδρασης των επιμέρους χαρακτηριστικών στην τελική πρόβλεψη.

### 7.3.3 Σχόλια για τη βελτίωση της οπτικοποίησης

Παρά τη σημαντική συνεισφορά των υφιστάμενων γραφικών, υπάρχουν περιθώρια περαιτέρω βελτίωσης της οπτικοποίησης, σύμφωνα με τις σύγχρονες πρακτικές της επιστήμης δεδομένων και της ιατρικής πληροφορικής [4]. Η ενσωμάτωση επιπλέον διαγραμμάτων, όπως boxplots για τη σύγκριση υποομάδων (π.χ. ανά φύλο, ηλικιακή ομάδα ή παρουσία οστεοπόρωσης), θα μπορούσε να προσφέρει βαθύτερη κατανόηση της ετερογένειας του πληθυσμού και της συμπεριφοράς του μοντέλου σε διαφορετικά προφίλ ασθενών.

Επιπλέον, η δυνατότητα εξατομικευμένων γραφικών, όπου ο χρήστης θα μπορεί να επιλέγει τα χαρακτηριστικά που τον ενδιαφέρουν και να παρακολουθεί τη μεταβολή της πρόβλεψης σε πραγματικό χρόνο (π.χ. μέσω sliders ή what-if analysis), θα ενίσχυε περαιτέρω τη διαδραστικότητα και τη χρηστικότητα της εφαρμογής [3]. Τέλος, η προσθήκη επεξηγηματικών εργαλείων (tooltips, legends, επεξηγηματικά μηνύματα) και η βελτιστοποίηση της χρωματικής παλέτας για άτομα με δυσχρωματοψία θα συνέβαλαν στη βελτίωση της προσβασιμότητας και της εκπαιδευτικής αξίας των γραφικών.

## 7.4 Προτάσεις Βελτίωσης και Μελλοντική Χρήση

Η εφαρμογή Streamlit που παρουσιάστηκε αποτελεί ένα σύγχρονο και διαδραστικό εργαλείο για την πρόβλεψη του χρόνου αποκατάστασης μετά από κάταγμα της περιφερικής κερκίδας, αξιοποιώντας προηγμένα μοντέλα μηχανικής μάθησης και συνθετικά δεδομένα. Παρά τα σημαντικά πλεονεκτήματα

που προσφέρει, υπάρχουν περιθώρια περαιτέρω βελτίωσης και επέκτασης, σύμφωνα με τις σύγχρονες τάσεις της ιατρικής πληροφορικής και της επιστήμης δεδομένων [1] [4].

Μια βασική κατεύθυνση για μελλοντική ανάπτυξη αφορά την ενσωμάτωση πραγματικών κλινικών δεδομένων, με στόχο τη βελτίωση της γενικευσιμότητας και της αξιοπιστίας των προβλέψεων. Η διασύνδεση της εφαρμογής με ηλεκτρονικά αρχεία υγείας (EHRs) και η αυτόματη εξαγωγή δεδομένων θα μπορούσαν να διευκολύνουν τη χρήση της στην καθημερινή κλινική πράξη, μειώνοντας τα σφάλματα εισαγωγής και ενισχύοντας την εξατομίκευση των προβλέψεων. Επιπλέον, η προσθήκη λειτουργιών όπως η αποθήκευση ιστορικού προβλέψεων, η δημιουργία λογαριασμών χρηστών (login) και η δυνατότητα εξαγωγής αναφορών θα ενίσχυαν τη χρηστικότητα και την ασφάλεια της εφαρμογής.

Η επέκταση της εφαρμογής για την πρόβλεψη και άλλων κλινικών εκβάσεων ή για τη διαχείριση διαφορετικών παθήσεων αποτελεί επίσης μια σημαντική προοπτική. Η ενσωμάτωση επιπλέον μοντέλων μηχανικής μάθησης, η σύγκριση της απόδοσής τους και η χρήση τεχνικών ερμηνείας όπως τα SHAP values θα μπορούσαν να προσφέρουν βαθύτερη κατανόηση της λειτουργίας του συστήματος και να ενισχύσουν τη διαφάνεια [1].

Τέλος, η αξιολόγηση της εφαρμογής σε πραγματικές συνθήκες, μέσω πιλοτικών μελετών και ανατροφοδότησης από κλινικούς χρήστες, είναι απαραίτητη για τη συνεχή βελτίωση και την υπεύθυνη ενσωμάτωση στην κλινική πράξη. Η υιοθέτηση βέλτιστων πρακτικών ασφάλειας, η συμμόρφωση με κανονιστικά πλαίσια και η διασφάλιση της προστασίας των προσωπικών δεδομένων παραμένουν κρίσιμες προϋποθέσεις για την επιτυχή εφαρμογή τέτοιων εργαλείων στην υγεία [4].

Συνολικά, η εφαρμογή Streamlit αποτελεί ένα πολλά υποσχόμενο παράδειγμα αξιοποίησης της τεχνητής νοημοσύνης στην ιατρική, με σημαντικές δυνατότητες επέκτασης και βελτίωσης που θα ενισχύσουν τη χρηστικότητα, την αξιοπιστία και την κλινική της αξία.

### 7.5 Επίλογος

Το παρόν κεφάλαιο ανέλυσε διεξοδικά τη σχεδίαση, την υλοποίηση και τη λειτουργικότητα της εφαρμογής Streamlit για την πρόβλεψη του χρόνου αποκατάστασης μετά από κάταγμα της περιφερικής κερκίδας, αξιοποιώντας προηγμένα μοντέλα μηχανικής μάθησης και συνθετικά δεδομένα. Η εφαρμογή συνδυάζει φιλικότητα προς τον χρήστη, διαδραστικότητα και επιστημονική τεκμηρίωση, προσφέροντας ένα σύγχρονο εργαλείο υποστήριξης κλινικών αποφάσεων [4] [1].

Η ενσωμάτωση διαδραστικής διεπαφής, αυτόματου υπολογισμού σύνθετων δεικτών (risk score), γραφικής απεικόνισης και επεξηγηματικών εργαλείων ενισχύει τη διαφάνεια και την κατανόηση των προβλέψεων, καθιστώντας την εφαρμογή προσβάσιμη τόσο σε επαγγελματίες υγείας όσο και σε ερευνητές. Η αρχιτεκτονική του κώδικα ακολουθεί τις βέλτιστες πρακτικές της Python και της επιστήμης δεδομένων, διασφαλίζοντας αξιοπιστία, επεκτασιμότητα και ευκολία συντήρησης [4].

Παράλληλα, αναδείχθηκαν οι δυνατότητες περαιτέρω βελτίωσης και επέκτασης της εφαρμογής, όπως η ενσωμάτωση πραγματικών κλινικών δεδομένων, η διασύνδεση με ηλεκτρονικά αρχεία υγείας και η αξιολόγηση σε πραγματικές συνθήκες. Η εφαρμογή Streamlit αποτελεί χαρακτηριστικό παράδειγμα της δυναμικής που προσφέρει η τεχνητή νοημοσύνη στην ιατρική πληροφορική, συμβάλλοντας στη βελτίωση της ποιότητας της φροντίδας και στην ενίσχυση της εμπιστοσύνης των χρηστών στα ψηφιακά προγνωστικά εργαλεία [1].

## Κεφάλαιο 8ο: Συμπεράσματα και Μελλοντική Εργασία

### 8.1 Συνοπτικά Ευρήματα

Η παρούσα εργασία ανέπτυξε και αξιολόγησε ένα ολοκληρωμένο σύστημα πρόβλεψης του χρόνου αποκατάστασης μετά από κάταγμα της περιφερικής κερκίδας, αξιοποιώντας συνθετικά δεδομένα και σύγχρονες τεχνικές μηχανικής μάθησης. Αρχικά, δημιουργήθηκε ένα συνθετικό σύνολο δεδομένων που αναπαριστά με ρεαλισμό κλινικά και λειτουργικά χαρακτηριστικά ασθενών, επιτρέποντας την εκπαίδευση και τη δοκιμή αλγορίθμων χωρίς τον κίνδυνο παραβίασης προσωπικών δεδομένων [1]. Η χρήση συνθετικών δεδομένων διευκολύνει την πειραματική αξιολόγηση των μοντέλων και την ταχεία ανάπτυξη εφαρμογών, ενώ παράλληλα διασφαλίζει τη συμμόρφωση με κανονιστικά πλαίσια προστασίας της ιδιωτικότητας.

Η ανάλυση σημασίας χαρακτηριστικών (feature importance) και οι τεχνικές ερμηνείας (όπως τα SHAP values) ανέδειξαν ως σημαντικότερους προγνωστικούς παράγοντες την ηλικία, τον δείκτη παράλληλων παθήσεων (Charlson Index), την παρουσία οστεοπόρωσης, τη σταθερότητα του κατάγματος και τη διάρκεια ακινητοποίησης. Τα αποτελέσματα αυτά συνάδουν με τα δεδομένα της διεθνούς βιβλιογραφίας και επιβεβαιώνουν τη βιολογική και κλινική σημασία των μεταβλητών αυτών στη διαδικασία αποκατάστασης [37][1].

Το εκπαιδευμένο μοντέλο XGBoost παρουσίασε ικανοποιητική ακρίβεια πρόβλεψης στο συνθετικό σύνολο δεδομένων, με δείκτες απόδοσης που καταδεικνύουν τη δυνατότητα αξιοποίησης τέτοιων εργαλείων στην υποστήριξη κλινικών αποφάσεων. Η ανάπτυξη της διαδραστικής εφαρμογής «Streamlit» επέτρεψε την άμεση εισαγωγή δεδομένων, τον αυτόματο υπολογισμό σύνθετων δεικτών (risk score) και την οπτικοποίηση των αποτελεσμάτων, ενισχύοντας τη διαφάνεια και τη χρηστικότητα του συστήματος [4].

Συνολικά, η εργασία αυτή τεκμηριώνει τη σκοπιμότητα και τη δυναμική αξιοποίησης συνθετικών δεδομένων και διαδραστικών εφαρμογών μηχανικής μάθησης στην ιατρική πληροφορική, θέτοντας τις βάσεις για μελλοντική εφαρμογή και επικύρωση σε πραγματικά κλινικά δεδομένα.

### 8.2 Πλεονεκτήματα και Περιορισμοί

Η χρήση συνθετικών δεδομένων και διαδραστικών εφαρμογών μηχανικής μάθησης στην ιατρική πληροφορική προσφέρει σημαντικά πλεονεκτήματα, αλλά συνοδεύεται και από ορισμένους περιορισμούς που πρέπει να λαμβάνονται υπόψη κατά την ερμηνεία των αποτελεσμάτων και τον σχεδιασμό μελλοντικών εφαρμογών [1].

Ένα βασικό πλεονέκτημα της προσέγγισης αυτής είναι η δυνατότητα ανάπτυξης και αξιολόγησης αλγορίθμων χωρίς την ανάγκη πρόσβασης σε ευαίσθητα προσωπικά δεδομένα, γεγονός που διευκολύνει τη συμμόρφωση με κανονιστικά πλαίσια προστασίας ιδιωτικότητας (GDPR, HIPAA) και επιταχύνει την ερευνητική διαδικασία. Επιπλέον, τα συνθετικά δεδομένα επιτρέπουν τη δημιουργία μεγάλων και ισορροπημένων συνόλων, ενισχύοντας τη στατιστική ισχύ και τη δυνατότητα πειραματισμού με διαφορετικά σενάρια [1]. Η χρήση διαδραστικών εφαρμογών, όπως το Streamlit, προσφέρει φιλικότητα προς τον χρήστη, άμεση οπτικοποίηση των αποτελεσμάτων και δυνατότητα ταχείας διάχυσης των εργαλείων στην ερευνητική και κλινική κοινότητα [4].

Ωστόσο, τα συνθετικά δεδομένα δεν μπορούν να αντικαταστήσουν πλήρως τα πραγματικά κλινικά δεδομένα, καθώς ενδέχεται να μην αποτυπώνουν πλήρως την πολυπλοκότητα, την ετερογένεια και τις

σπάνιες αλληλεπιδράσεις που παρατηρούνται στον πραγματικό πληθυσμό [3]. Υπάρχει επίσης ο κίνδυνος εισαγωγής μεροληψιών (bias) ή απώλειας σημαντικών πληροφοριών κατά τη διαδικασία δημιουργίας των συνθετικών δειγμάτων. Επιπλέον, η αξιολόγηση της απόδοσης των μοντέλων σε συνθετικά δεδομένα δεν εγγυάται απαραίτητα την ίδια απόδοση σε πραγματικά περιστατικά, καθιστώντας αναγκαία την επικύρωση και τη συνεχή βελτίωση των μοντέλων με βάση πραγματικά δεδομένα.

Συνοψίζοντας, η προσέγγιση που ακολουθήθηκε στην παρούσα εργασία προσφέρει σημαντικές ευκαιρίες για την ταχεία ανάπτυξη και αξιολόγηση εργαλείων μηχανικής μάθησης στην ιατρική, αλλά απαιτείται προσεκτική ερμηνεία των αποτελεσμάτων και περαιτέρω επικύρωση σε πραγματικές συνθήκες.

### 8.3 Προτάσεις για Εφαρμογή σε Πραγματικά Δεδομένα

Η μετάβαση από τη χρήση συνθετικών δεδομένων στην αξιοποίηση πραγματικών κλινικών δεδομένων αποτελεί κρίσιμο βήμα για την επικύρωση και τη βελτίωση των μοντέλων μηχανικής μάθησης στην ιατρική πράξη [3]. Η συλλογή, ανωνυμοποίηση και ορθή διαχείριση πραγματικών δεδομένων ασθενών είναι απαραίτητη για την εξασφάλιση της εγκυρότητας και της γενικευσιμότητας των προγνωστικών εργαλείων. Η ενσωμάτωση δεδομένων από διαφορετικά κλινικά περιβάλλοντα και πληθυσμούς θα επιτρέψει την ανίχνευση πιθανών μεροληψιών και τη βελτίωση της ακρίβειας των μοντέλων [3].

Η επικύρωση των μοντέλων σε πραγματικά περιστατικά αποτελεί αναγκαία προϋπόθεση για την υπεύθυνη ενσωμάτωσή τους στην κλινική πράξη. Μέσω της σύγκρισης των προβλέψεων με πραγματικές εκβάσεις, μπορούν να εντοπιστούν αδυναμίες, να προσαρμοστούν οι παράμετροι του μοντέλου και να βελτιωθεί η αξιοπιστία του συστήματος. Παράλληλα, η ενεργή συμμετοχή και η ανατροφοδότηση από κλινικούς ιατρούς είναι καθοριστικής σημασίας για την προσαρμογή της εφαρμογής στις πραγματικές ανάγκες της καθημερινής κλινικής πρακτικής και για τη διασφάλιση της αποδοχής και της χρηστικότητάς της [4].

Επιπλέον, η συμμόρφωση με τα κανονιστικά πλαίσια προστασίας προσωπικών δεδομένων (όπως ο GDPR) και η υιοθέτηση βέλτιστων πρακτικών ασφάλειας αποτελούν αναγκαίες προϋποθέσεις για τη συλλογή και επεξεργασία πραγματικών δεδομένων. Η ανάπτυξη κατάλληλων διαδικασιών ανωνυμοποίησης και η διασφάλιση της εμπιστευτικότητας των πληροφοριών είναι θεμελιώδεις για την προστασία των ασθενών και την ενίσχυση της εμπιστοσύνης στην τεχνητή νοημοσύνη στην υγεία [3].

Συνολικά, η εφαρμογή και η επικύρωση των μοντέλων σε πραγματικά δεδομένα, σε συνδυασμό με τη συνεχή ανατροφοδότηση από τους τελικούς χρήστες, θα συμβάλει ουσιαστικά στη βελτίωση της ακρίβειας, της αξιοπιστίας και της κλινικής αξίας των προγνωστικών εργαλείων μηχανικής μάθησης.

### 8.4 Δυνατότητες Επέκτασης της Έρευνας

Η παρούσα εργασία θέτει τις βάσεις για περαιτέρω ερευνητική δραστηριότητα και τεχνολογική ανάπτυξη στον τομέα της ιατρικής μηχανικής μάθησης, με πολλαπλές δυνατότητες επέκτασης τόσο σε μεθοδολογικό όσο και σε εφαρμοστικό επίπεδο. Μια βασική προοπτική αφορά την εφαρμογή της προτεινόμενης μεθοδολογίας σε άλλες παθήσεις ή τύπους καταγμάτων, διευρύνοντας το φάσμα των κλινικών ερωτημάτων που μπορούν να αντιμετωπιστούν με τη χρήση συνθετικών και πραγματικών δεδομένων [3]. Η ενσωμάτωση επιπλέον κλινικών και λειτουργικών δεικτών, όπως βιοχημικών παραμέτρων, δείκτες λειτουργικότητας ή κοινωνικοοικονομικοί παράγοντες, θα μπορούσε να ενισχύσει την προγνωστική ικανότητα και τη χρηστικότητα των μοντέλων.

Παράλληλα, η ανάπτυξη πιο σύνθετων ή ερμηνεύσιμων αλγορίθμων, όπως νευρωνικών δικτύων με ενσωματωμένες τεχνικές ερμηνείας (π.χ. SHAP, LIME), μπορεί να προσφέρει βαθύτερη κατανόηση των μηχανισμών που διέπουν τις κλινικές εκβάσεις και να ενισχύσει τη διαφάνεια των συστημάτων τεχνητής νοημοσύνης[3]. Η αξιοποίηση τεχνικών μεταφοράς μάθησης (transfer learning) και η εκπαίδευση μοντέλων σε δεδομένα πολλαπλών κέντρων θα μπορούσαν να βελτιώσουν τη γενικευσιμότητα και την αξιοπιστία των προγνωστικών εργαλείων.

Ιδιαίτερο ενδιαφέρον παρουσιάζει η ενσωμάτωση της εφαρμογής σε ηλεκτρονικά αρχεία υγείας (EHRs), επιτρέποντας την αυτόματη εξαγωγή και ανάλυση δεδομένων σε πραγματικό χρόνο καθώς και τη διασύνδεση με τα υπάρχοντα κλινικά συστήματα [4]. Η διαδραστική επικοινωνία με τους κλινικούς χρήστες και η συλλογή ανατροφοδότησης θα συμβάλουν στη συνεχή βελτίωση της εφαρμογής και στην προσαρμογή της στις πραγματικές ανάγκες της κλινικής πράξης.

Συνολικά, η επέκταση της έρευνας προς τις παραπάνω κατευθύνσεις θα ενισχύσει τη συμβολή της τεχνητής νοημοσύνης στην ιατρική, προάγοντας την εξατομικευμένη φροντίδα, τη διαφάνεια και την υπεύθυνη χρήση των ψηφιακών προγνωστικών εργαλείων.

## 8.5 Επίλογος

Τέλος το κεφάλαιο συνοψίζει τα βασικά ευρήματα, τα πλεονεκτήματα, τους περιορισμούς και τις μελλοντικές προοπτικές της παρούσας ερευνητικής εργασίας, η οποία εστιάζει στην ανάπτυξη και αξιολόγηση ενός συστήματος πρόβλεψης χρόνου αποκατάστασης με χρήση συνθετικών δεδομένων και τεχνικών μηχανικής μάθησης. Η εργασία ανέδειξε τη χρησιμότητα των συνθετικών δεδομένων για την ασφαλή και ταχεία ανάπτυξη προγνωστικών μοντέλων, καθώς και τη σημασία της διαδραστικής εφαρμογής για τη γεφύρωση του χάσματος μεταξύ έρευνας και κλινικής [1].

Η ανάλυση ανέδειξε ως σημαντικότερους προγνωστικούς παράγοντες την ηλικία, τον δείκτη συνοσηροτήτων, την οστεοπόρωση και τη σταθερότητα του κατάγματος, επιβεβαιώνοντας τη βιβλιογραφία και τη βιολογική σημασία αυτών των μεταβλητών. Παράλληλα, επισημάνθηκαν οι περιορισμοί της χρήσης συνθετικών δεδομένων, όπως η πιθανή απώλεια πολυπλοκότητας και η ανάγκη επικύρωσης των μοντέλων σε πραγματικά περιστατικά [1].

Η μελλοντική εργασία θα πρέπει να επικεντρωθεί στη συλλογή και ανάλυση πραγματικών δεδομένων, στην επικύρωση και βελτίωση των μοντέλων, καθώς και στην ενσωμάτωση της εφαρμογής σε κλινικά πληροφοριακά συστήματα [4]. Η επέκταση της μεθοδολογίας σε άλλες παθήσεις και η ενσωμάτωση περισσότερων κλινικών δεικτών θα ενισχύσουν περαιτέρω τη χρηστικότητα και την επιστημονική αξία των προγνωστικών εργαλείων.

Συμπερασματικά, η διπλωματική καταδεικνύει τη δυναμική της τεχνητής νοημοσύνης και των συνθετικών δεδομένων στην ιατρική πληροφορική, θέτοντας τις βάσεις για υπεύθυνη, διαφανή και αποτελεσματική αξιοποίηση των ψηφιακών εργαλείων στην κλινική πράξη.

## ΒΙΒΛΙΟΓΡΑΦΙΑ

- [1] C. M. Bishop, Pattern recognition and machine learning. in Information science and statistics. New York: Springer, 2006.
- [2] A. Géron, Hands-on machine learning with Scikit-Learn, Keras, and TensorFlow: concepts, tools, and techniques to build intelligent systems, Second edition. Beijing Boston Farnham Sebastopol Tokyo: O'Reilly, 2019.
- [3] R. J. Chen, M. Y. Lu, T. Y. Chen, D. F. K. Williamson, and F. Mahmood, “Synthetic data in machine learning for medicine and healthcare,” *Nat Biomed Eng*, vol. 5, no. 6, pp. 493–497, Jun. 2021, doi: 10.1038/s41551-021-00751-8.
- [4] W. McKinney, Python for data analysis, First Edition, Third release. Beijing Cambridge Farnham Köln Sebastopol Tokyo: O'Reilly, 2014.
- [5] T. Hastie, R. Tibshirani, and J. H. Friedman, The elements of statistical learning: data mining, inference, and prediction, 2nd ed. in Springer series in statistics. New York, NY: Springer, 2009.
- [6] T. M. Mitchell, Machine Learning. in McGraw-Hill series in computer science. New York: McGraw-Hill, 1997.
- [7] E. J. Topol, “High-performance medicine: the convergence of human and artificial intelligence,” *Nat Med*, vol. 25, no. 1, pp. 44–56, Jan. 2019, doi: 10.1038/s41591-018-0300-7.
- [8] L. Breiman, “Random Forests,” *Machine Learning*, vol. 45, no. 1, pp. 5–32, 2001, doi: 10.1023/a:1010933404324.
- [9] I. Goodfellow, Y. Bengio, and A. Courville, Deep learning. in Adaptive computation and machine learning. Cambridge, Massachusetts: The MIT Press, 2016.
- [10] C. Molnar, *Interpretable machine learning: a guide for making black box models explainable*. Victoria, British Columbia: Leanpub, 2020.
- [11] S. M. Lundberg et al., “From local explanations to global understanding with explainable AI for trees,” *Nat Mach Intell*, vol. 2, no. 1, pp. 56–67, Jan. 2020, doi: 10.1038/s42256-019-0138-9.
- [12] M. M. Girod et al., “Artificial Intelligence in the Diagnosis and Prognostication of the Musculoskeletal Patient,” *HSS Journal®: The Musculoskeletal Journal of Hospital for Special Surgery*, vol. 21, no. 3, pp. 257–266, Aug. 2025, doi: 10.1177/15563316251339660.
- [13] W. Zhang, L. Wang, X. Zhang, Q. Zhang, B. Liang, and B. Zhang, “Manual passive rehabilitation program for geriatric distal radius fractures,” *Medicine*, vol. 100, no. 3, p. e24074, Jan. 2021, doi: 10.1097/md.0000000000024074.
- [14] B. Shickel, P. J. Tighe, A. Bihorac, and P. Rashidi, “Deep EHR: A Survey of Recent Advances in Deep Learning Techniques for Electronic Health Record (EHR) Analysis,” *IEEE J. Biomed. Health Inform.*, vol. 22, no. 5, pp. 1589–1604, Sep. 2018, doi: 10.1109/jbhi.2017.2767063.
- [15] A. Yasser and M. M. Solayman, “Computer-Based Machine Learning Model for Supporting and Healing ACL Injury for Athletes,” in *2024 Intelligent Methods, Systems, and Applications (IMSA)*, Giza, Egypt: IEEE, Jul. 2024, pp. 610–615. doi: 10.1109/imsa61967.2024.10652749.
- [16] H. Asadi, R. Dowling, B. Yan, and P. Mitchell, “Machine Learning for Outcome Prediction of Acute Ischemic Stroke Post Intra-Arterial Therapy,” *PLOS ONE*, vol. 9, no. 2, 2014.

- [17] J. T. Senders et al., “An introduction and overview of machine learning in neurosurgical care,” *Acta Neurochir*, vol. 160, no. 1, pp. 29–38, Jan. 2018, doi: 10.1007/s00701-017-3385-8.
- [18] D. Wennergren, C. Ekholm, A. Sandelin, and M. Möller, “The Swedish fracture register: 103,000 fractures registered,” *BMC Musculoskelet Disord*, vol. 16, no. 1, Dec. 2015, doi: 10.1186/s12891-015-0795-8.
- [19] A. E. W. Johnson et al., “MIMIC-III, a freely accessible critical care database,” *Sci Data*, vol. 3, no. 1, May 2016, doi: 10.1038/sdata.2016.35.
- [20] C. Tian, Y. Gao, C. Rui, S. Qin, L. Shi, and Y. Rui, “Artificial intelligence in orthopaedic trauma,” *EngMedicine*, vol. 1, no. 2, p. 100020, Sep. 2024, doi: 10.1016/j.engmed.2024.100020.
- [21] J. Jordon, J. Yoon, and M. van der Schaar, “Measuring the quality of Synthetic data for use in competitions,” Jun. 29, 2018, arXiv: arXiv:1806.11345. doi: 10.48550/arXiv.1806.11345.
- [22] C. Lin, Z. Liang, J. Liu, and W. Sun, “A machine learning-based prediction model pre-operatively for functional recovery after 1-year of hip fracture surgery in older people,” *Front. Surg.*, vol. 10, Jun. 2023, doi: 10.3389/fsurg.2023.1160085.
- [23] M. B. Whyte et al., “Early and ongoing stable glycaemic control is associated with a reduction in major adverse cardiovascular events in people with type 2 diabetes: A primary care cohort study,” *Diabetes Obesity Metabolism*, vol. 24, no. 7, pp. 1310–1318, Jul. 2022, doi: 10.1111/dom.14705.
- [24] A. V. Karhade et al., “Predicting 90-Day and 1-Year Mortality in Spinal Metastatic Disease: Development and Internal Validation,” *Neurosurg.*, vol. 85, no. 4, pp. E671–E681, Oct. 2019, doi: 10.1093/neuros/nyz070.
- [25] on behalf of the Scientific Advisory Board of the European Society for Clinical and Economic Aspects of Osteoporosis (ESCEO) and the Committees of Scientific Advisors and National Societies of the International Osteoporosis Foundation (IOF), J. A. Kanis, C. Cooper, R. Rizzoli, and J.-Y. Reginster, “European guidance for the diagnosis and management of osteoporosis in postmenopausal women,” *Osteoporos Int*, vol. 30, no. 1, pp. 3–44, Jan. 2019, doi: 10.1007/s00198-018-4704-5.
- [26] Bailey, M. (2022, November 21). Physical Therapy for a Colles’ Fracture. Verywell Health. <https://www.verywellhealth.com/physical-therapy-for-a-colles-fracture-2696058>
- [27] Z. Zhou, X. Li, X. Wu, and X. Wang, “Impact of early rehabilitation therapy on functional outcomes in patients post distal radius fracture surgery: a systematic review and meta-analysis,” *BMC Musculoskelet Disord*, vol. 25, no. 1, Mar. 2024, doi: 10.1186/s12891-024-07317-0.
- [28] R. A. Washburn, K. W. Smith, A. M. Jette, and C. A. Janney, “The physical activity scale for the elderly (PASE): Development and evaluation,” *Journal of Clinical Epidemiology*, vol. 46, no. 2, pp. 153–162, Feb. 1993, doi: 10.1016/0895-4356(93)90053-4.
- [29] A. Goncalves, P. Ray, B. Soper, J. Stevens, L. Coyle, and A. P. Sales, “Generation and evaluation of synthetic patient data,” *BMC Med Res Methodol*, vol. 20, no. 1, Dec. 2020, doi: 10.1186/s12874-020-00977-1.
- [30] H. A. W. Meijer et al., “Rehabilitation after Distal Radius Fractures: Opportunities for Improvement,” *J Wrist Surg*, vol. 12, no. 05, pp. 460–473, Oct. 2023, doi: 10.1055/s-0043-1769925.
- [31] J. C. MacDermid, J. H. Roth, and R. S. Richards, “Pain and disability reported in the year following a distal radius fracture: A cohort study,” *BMC Musculoskelet Disord*, vol. 4, no. 1, Oct. 2003, doi: 10.1186/1471-2474-4-24.

- [32] Y. Mahmoud, J. Chung, W. Pirzada, and A. M. Ilyas, “Understanding Changing Demographic and Treatment Trends of Distal Radius Fractures: A TriNetX Database Contemporary Analysis of 32,912 Patients,” *Journal of Hand Surgery Global Online*, vol. 6, no. 4, pp. 477–483, Jul. 2024, doi: 10.1016/j.jhsg.2024.01.005.
- [33] T. Chen and C. Guestrin, “XGBoost: A Scalable Tree Boosting System,” in *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, San Francisco California USA: ACM, Aug. 2016, pp. 785–794. doi: 10.1145/2939672.2939785.
- [34] S. Lundberg and S.-I. Lee, “A Unified Approach to Interpreting Model Predictions,” 2017, arXiv. doi: 10.48550/ARXIV.1705.07874.
- [35] F. Doshi-Velez and B. Kim, “Towards A Rigorous Science of Interpretable Machine Learning,” 2017, arXiv. doi: 10.48550/ARXIV.1702.08608.
- [36] M. E. Charlson, P. Pompei, K. L. Ales, and C. R. MacKenzie, “A new method of classifying prognostic comorbidity in longitudinal studies: Development and validation,” *Journal of Chronic Diseases*, vol. 40, no. 5, pp. 373–383, Jan. 1987, doi: 10.1016/0021-9681(87)90171-8.
- [37] “17. A Value for n-Person Games,” in *Contributions to the Theory of Games (AM-28), Volume II*, Princeton University Press, 1953, pp. 307–318. doi: 10.1515/9781400881970-018.
- [38] Z. Obermeyer, B. Powers, C. Vogeli, and S. Mullainathan, “Dissecting racial bias in an algorithm used to manage the health of populations,” *Science*, vol. 366, no. 6464, pp. 447–453, Oct. 2019, doi: 10.1126/science.aax2342.
- [39] Y. LeCun, Y. Bengio, and G. Hinton, “Deep learning,” *Nature*, vol. 521, no. 7553, pp. 436–444, May 2015, doi: 10.1038/nature14539.
- [40] J. Schmidhuber, “Deep learning in neural networks: An overview,” *Neural Networks*, vol. 61, pp. 85–117, Jan. 2015, doi: 10.1016/j.neunet.2014.09.003.
- [41] A. Shrikumar, P. Greenside, and A. Kundaje, “Learning Important Features Through Propagating Activation Differences”.
- [42] M. T. Ribeiro, S. Singh, and C. Guestrin, “‘Why Should I Trust You?’: Explaining the Predictions of Any Classifier,” in *Proceedings of the 22nd ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, San Francisco California USA: ACM, Aug. 2016, pp. 1135–1144. doi: 10.1145/2939672.2939778.
- [43] A. Arshi, K. Rezzadeh, A. I. Stavrakis, S. V. Bukata, and E. N. Zeegen, “Standardized Hospital-Based Care Programs Improve Geriatric Hip Fracture Outcomes: An Analysis of the ACS NSQIP Targeted Hip Fracture Series,” *Journal of Orthopaedic Trauma*, vol. 33, no. 6, pp. e223–e228, Jun. 2019, doi: 10.1097/bot.0000000000001443.
- [44] C. A. Brauer, M. Coca-Perrillon, D. M. Cutler, and A. B. Rosen, “Incidence and Mortality of Hip Fractures in the United States,” 1986.
- [45] A. W. Brinlee, S. B. Dickenson, A. Hunter-Giordano, and L. Snyder-Mackler, “ACL Reconstruction Rehabilitation: Clinical Data, Biologic Healing, and Criterion-Based Milestones to Inform a Return-to-Sport Guideline,” *Sports Health: A Multidisciplinary Approach*, vol. 14, no. 5, pp. 770–779, Sep. 2022, doi: 10.1177/19417381211056873.
- [46] K. C. Chung et al., “Predicting Outcomes After Distal Radius Fracture: A 24-Center International Clinical Trial of Older Adults,” *The Journal of Hand Surgery*, vol. 44, no. 9, pp. 762–771, Sep. 2019, doi: 10.1016/j.jhsg.2019.05.016.

- [47] H. Dijkstra et al., “Systematic review of machine-learning models in orthopaedic trauma: an overview and quality assessment of 45 studies,” *Bone Jt Open*, vol. 5, no. 1, pp. 9–19, Jan. 2024, doi: 10.1302/2633-1462.51.bjo-2023-0095.r1.
- [48] L.-P. Granan, M. Forssblad, M. Lind, and L. Engebretsen, “The Scandinavian ACL registries 2004–2007: baseline epidemiology,” *Acta Orthopaedica*, vol. 80, no. 5, pp. 563–567, Oct. 2009, doi: 10.3109/17453670903350107.
- [49] H. Grindem, L. Snyder-Mackler, H. Moksnes, L. Engebretsen, and M. A. Risberg, “Simple decision rules can reduce reinjury risk by 84% after ACL reconstruction: the Delaware-Oslo ACL cohort study,” *Br J Sports Med*, vol. 50, no. 13, pp. 804–808, Jul. 2016, doi: 10.1136/bjsports-2016-096031.
- [50] S. Jauhiainen, J.-P. Kauppi, T. Krosshaug, R. Bahr, J. Bartsch, and S. Äyrämö, “Predicting ACL Injury Using Machine Learning on Data From an Extensive Screening Test Battery of 880 Female Elite Athletes,” *Am J Sports Med*, vol. 50, no. 11, pp. 2917–2924, Sep. 2022, doi: 10.1177/03635465221112095.
- [51] C.-H. Lai, P. K.-L. Mok, W.-W. Chau, and S.-W. Law, “Application of machine learning models on predicting the length of hospital stay in fragility fracture patients,” *BMC Med Inform Decis Mak*, vol. 24, no. 1, Jan. 2024, doi: 10.1186/s12911-024-02417-2.
- [52] S. P. Lalehzarian, A. K. Gowd, and J. N. Liu, “Machine learning in orthopaedic surgery,” *WJO*, vol. 12, no. 9, pp. 685–699, Sep. 2021, doi: 10.5312/wjo.v12.i9.685.
- [53] P. Liuzzi et al., “Predicting 60-day Recovery Outcomes After ACL Surgery Using Machine Learning,” *Gait & Posture*, vol. 114, p. S26, Oct. 2024, doi: 10.1016/j.gaitpost.2024.08.048.
- [54] S. Padash et al., “An Overview of Machine Learning in Orthopedic Surgery: An Educational Paper,” *The Journal of Arthroplasty*, vol. 38, no. 10, pp. 1938–1942, Oct. 2023, doi: 10.1016/j.arth.2023.08.043.
- [55] A. G. Potty et al., “Approaching Artificial Intelligence in Orthopaedics: Predictive Analytics and Machine Learning to Prognosticate Arthroscopic Rotator Cuff Surgical Outcomes,” *JCM*, vol. 12, no. 6, p. 2369, Mar. 2023, doi: 10.3390/jcm12062369.
- [56] A. Rajkomar, J. Dean, and I. Kohane, “Machine Learning in Medicine,” *N Engl J Med*, vol. 380, no. 14, pp. 1347–1358, Apr. 2019, doi: 10.1056/nejmra1814259.
- [57] M. Rezapour, R. B. Seymour, S. H. Sims, M. A. Karunakar, N. Habet, and M. N. Gurcan, “Employing machine learning to enhance fracture recovery insights through gait analysis,” *Journal Orthopaedic Research*, vol. 42, no. 8, pp. 1748–1761, Aug. 2024, doi: 10.1002/jor.25837.
- [58] L. Sánchez-Guillén et al., “A calculator for musculoskeletal injuries prediction in surgeons: a machine learning approach,” *Surg Endosc*, vol. 38, no. 11, pp. 6577–6585, Nov. 2024, doi: 10.1007/s00464-024-11237-4.
- [59] M. Tschuggnall, V. Grote, M. Pirchl, B. Holzner, G. Rumpold, and M. J. Fischer, “Machine learning approaches to predict rehabilitation success based on clinical and patient-reported outcome measures,” *Informatics in Medicine Unlocked*, vol. 24, p. 100598, 2021, doi: 10.1016/j.imu.2021.100598.
- [60] L. Xu, M. Skoularidou, A. Cuesta-Infante, and K. Veeramachaneni, “Modeling Tabular data using Conditional GAN,” Oct. 28, 2019, arXiv: arXiv:1907.00503. doi: 10.48550/arXiv.1907.00503.

- [61] H.-J. Yoo, K.-S. Lee, B. Koo, C.-W. Yong, and C.-W. Kim, “Deep Learning-Based Prediction Model for Gait Recovery after a Spinal Cord Injury,” *Diagnostics*, vol. 14, no. 6, p. 579, Mar. 2024, doi: 10.3390/diagnostics14060579.
- [62] R. K. Martin et al., “Predicting Anterior Cruciate Ligament Reconstruction Revision: A Machine Learning Analysis Utilizing the Norwegian Knee Ligament Register,” *Journal of Bone and Joint Surgery*, vol. 104, no. 2, pp. 145–153, Jan. 2022, doi: 10.2106/jbjs.21.00113.
- [63] A. G. J. Bot and D. C. Ring, “Recovery After Fracture of the Distal Radius,” *Hand Clinics*, vol. 28, no. 2, pp. 235–243, May 2012, doi: 10.1016/j.hcl.2012.03.006.
- [64] K. C. Chung et al., “Comparison of 24-Month Outcomes After Treatment for Distal Radius Fracture: The WRIST Randomized Clinical Trial,” *JAMA Netw Open*, vol. 4, no. 6, p. e2112710, Jun. 2021, doi: 10.1001/jamanetworkopen.2021.12710.
- [65] A. Cronström, M. W. Creaby, and E. Ageberg, “Do knee abduction kinematics and kinetics predict future anterior cruciate ligament injury risk? A systematic review and meta-analysis of prospective studies,” *BMC Musculoskelet Disord*, vol. 21, no. 1, Dec. 2020, doi: 10.1186/s12891-020-03552-3.
- [66] H. D. W. T. Damayanthi, F. M. Moy, K. L. Abdullah, and S. D. Dharmaratne, “Prevalence of malnutrition and associated factors among community-dwelling older persons in Sri Lanka: a cross-sectional study,” *BMC Geriatr*, vol. 18, no. 1, Dec. 2018, doi: 10.1186/s12877-018-0892-2.
- [67] C. Dillingham, M. Horodyski, A. M. Struk, and T. Wright, “Rate of Improvement following Volar Plate Open Reduction and Internal Fixation of Distal Radius Fractures,” *Advances in Orthopedics*, vol. 2011, pp. 1–4, 2011, doi: 10.4061/2011/565642.
- [68] D. E. Ehrmann, S. Joshi, S. D. Goodfellow, M. L. Mazwi, and D. Eytan, “Making machine learning matter to clinicians: model actionability in medical decision-making,” *npj Digit. Med.*, vol. 6, no. 1, Jan. 2023, doi: 10.1038/s41746-023-00753-7.
- [69] K. O. T. Koo, D. M. K. Tan, and A. K. S. Chong, “Distal Radius Fractures: An Epidemiological Review,” *Orthopaedic Surgery*, vol. 5, no. 3, pp. 209–213, Aug. 2013, doi: 10.1111/os.12045.
- [70] C.-R. Lee, I. Cho, B. Jeong, and S. Lee, “Strategies to Minimize Antibiotic Resistance,” *IJERPH*, vol. 10, no. 9, pp. 4274–4305, Sep. 2013, doi: 10.3390/ijerph10094274.
- [71] J. Lim, S. Chang, K. Kim, H. J. Park, E. Kim, and S. W. Hong, “Machine learning-based prediction of the necessity for the surgical treatment of distal radius fractures,” *J Orthop Surg Res*, vol. 20, no. 1, Apr. 2025, doi: 10.1186/s13018-025-05830-z.
- [72] X. Liu, S. Miramini, M. Patel, P. Ebeling, J. Liao, and L. Zhang, “Development of numerical model-based machine learning algorithms for different healing stages of distal radius fracture healing,” *Computer Methods and Programs in Biomedicine*, vol. 233, p. 107464, May 2023, doi: 10.1016/j.cmpb.2023.107464.
- [73] Y. Ochen et al., “Operative vs Nonoperative Treatment of Distal Radius Fractures in Adults: A Systematic Review and Meta-analysis,” *JAMA Netw Open*, vol. 3, no. 4, p. e203497, Apr. 2020, doi: 10.1001/jamanetworkopen.2020.3497.
- [74] S. B. Sequeira et al., “Machine Learning Improves Functional Upper Extremity Use Capture in Distal Radius Fracture Patients,” *Plastic and Reconstructive Surgery - Global Open*, vol. 10, no. 8, p. e4472, Aug. 2022, doi: 10.1097/gox.0000000000004472.

[75] L. M. Shapiro et al., “Distal Radius Fracture Clinical Practice Guidelines—Updates and Clinical Implications,” *The Journal of Hand Surgery*, vol. 46, no. 9, pp. 807–811, Sep. 2021, doi: 10.1016/j.jhsa.2021.07.014.

[76] O. Shareef, H. Huddleston, S. Jang, and D. Fufa, “A Deep Learning Model to Predict Surgical Recommendation of Distal Radius Fractures”.

[77] C. A. Hudson, C. A. McArdle, and A. López Bernal, “Steroid receptor co-activator interacting protein (SIP) mediates EGF-stimulated expression of the prostaglandin synthase COX2 and prostaglandin release in human myometrium,” *Mol. Hum. Reprod.*, vol. 22, no. 7, pp. 512–525, Jul. 2016, doi: 10.1093/molehr/gaw031.