



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ

ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ

ΔΠΜΣ ΕΠΙΣΤΗΜΗ ΔΕΔΟΜΕΝΩΝ & ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

**Ανίχνευση ιδιοπαθούς σκολίωσης  
σε εικόνες δύο διαστάσεων  
με χρήση τεχνικών Μηχανικής Μάθησης**

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

ΤΟΥ

**ΠΑΝΑΓΙΩΤΗ Γ. ΚΟΝΤΑΞΗ**

**Επιβλέπων:** Γεώργιος Ματσόπουλος  
Καθηγητής Ε.Μ.Π.

Αθήνα, Ιανουάριος 2023

---





# Ανίχνευση ιδιοπαθούς σκολίωσης σε εικόνες δύο διαστάσεων με χρήση τεχνικών Μηχανικής Μάθησης

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

ΤΟΥ

**ΠΑΝΑΓΙΩΤΗ Γ. ΚΟΝΤΑΞΗ**

**Επιβλέπων:** Γεώργιος Ματσόπουλος  
Καθηγητής Ε.Μ.Π.

Εγκρίθηκε από την τριμελή εξεταστική επιτροπή την 23η Ιανουαρίου 2023.

*(Υπογραφή)*

*(Υπογραφή)*

*(Υπογραφή)*

.....  
Γεώργιος Ματσόπουλος  
Καθηγητής Ε.Μ.Π.

.....  
Γεώργιος Στάμου  
Καθηγητής Ε.Μ.Π.

.....  
Παναγιώτης Τσανάκας  
Καθηγητής Ε.Μ.Π.





ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ

ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ ΥΠΟΛΟΓΙΣΤΩΝ

ΔΠΜΣ ΕΠΙΣΤΗΜΗ ΔΕΔΟΜΕΝΩΝ & ΜΗΧΑΝΙΚΗ ΜΑΘΗΣΗ

Copyright © - All rights reserved. Με την επιφύλαξη παντός δικαιώματος.  
Παναγιώτης Κονταξής, 2023.

Απαγορεύεται η αντιγραφή, αποθήκευση και διανομή της παρούσας εργασίας, εξ ολοκλήρου ή τμήματος αυτής, για εμπορικό σκοπό. Επιτρέπεται η ανατύπωση, αποθήκευση και διανομή για σκοπό μη κερδοσκοπικό, εκπαιδευτικής ή ερευνητικής φύσης, υπό την προϋπόθεση να αναφέρεται η πηγή προέλευσης και να διατηρείται το παρόν μήνυμα.

Το περιεχόμενο αυτής της εργασίας δεν απηχεί απαραίτητα τις απόψεις του Τμήματος, του Επιβλέποντα, ή της επιτροπής που την ενέκρινε.



## Περίληψη

---

Η ιδιοπαθής σκολίωση είναι μια πάθηση που προκαλεί μη φυσιολογική καμπυλότητα της σπονδυλικής στήλης. Συνήθως εμφανίζεται στο τέλος της παιδικής ηλικίας ή στην αρχή της εφηβείας και εξελίσσεται μέχρι το παιδί να ενηλικιωθεί. Η έγκαιρη διάγνωση της σκολίωσης παίζει σημαντικό ρόλο στη μετέπειτα πορεία της νόσου.

Η διάγνωση της ιδιοπαθούς σκολίωσης γίνεται μέσω ακτινογραφίας της σπονδυλικής στήλης ή μέσω ιατρικής εξέτασης στην οποία ο γιατρός παρατηρεί την πλάτη του παιδιού το οποίο βρίσκεται σε θέση επίκυψης, αναζητώντας ενδεχόμενη παραμόρφωση της σπονδυλικής στήλης.

Στην εργασία αυτή παρουσιάζεται μία μέθοδος διάγνωσης της ιδιοπαθούς σκολίωσης σε φωτογραφίες πλάτης ατόμων με χρήση τεχνικών Μηχανικής Μάθησης. Αρχικά δημιουργήθηκε ένα σύνολο δεδομένων εικόνων από την πλάτη υγιών ατόμων και ασθενών με σκολίωση. Από τις εικόνες αυτές έγινε επιλογή και εξαγωγή κατάλληλων χαρακτηριστικών για τη διάγνωση της σκολίωσης. Τα χαρακτηριστικά του συνόλου δεδομένων χρησιμοποιήθηκαν για την εκπαίδευση και την αξιολόγηση της απόδοσης τριών μοντέλων Μηχανικής Μάθησης για δυαδική ταξινόμηση: της Λογιστικής Παλινδρόμησης, των Μηχανών Διανυσμάτων Υποστήριξης και του Τυχαίου Δάσους. Η προβλεπτική ικανότητα των τριών παραπάνω μοντέλων που εκπαιδεύτηκαν για την αναγνώριση της σκολίωσης ήταν ικανοποιητική.

## Λέξεις Κλειδιά

Ιδιοπαθής Σκολίωση, Εξαγωγή Χαρακτηριστικών, Μηχανική Μάθηση, Δυαδική Ταξινόμηση, Λογιστική Παλινδρόμηση, Μηχανές Διανυσμάτων Υποστήριξης, Τυχαίο Δάσος





# Abstract

---

Idiopathic scoliosis is a condition that causes an abnormal curvature of the spine. It usually appears in late childhood or early adolescence and progresses until the child reaches adulthood. Early diagnosis of scoliosis plays an important role in the subsequent course of the disease.

The diagnosis of idiopathic scoliosis is made through an X-ray of the spine or through a medical examination in which the doctor observes the back of the child who is in a prone position, looking for possible deformation of the spine.

This Thesis presents a method for diagnosing scoliosis in photographs of people's backs using Machine Learning techniques. A dataset of back images of healthy individuals and patients with scoliosis was first created. From these images, appropriate features were selected and extracted for the diagnosis of scoliosis. The features of the dataset were used to train and evaluate the performance of three Machine Learning models for binary classification: Logistic Regression, Support Vector Machines and Random Forest. The predictive ability of the above three models trained to recognize scoliosis was satisfactory.

## Keywords

Idiopathic Scoliosis, Feature Extraction, Machine Learning, Binary Classification, Logistic Regression, Support Vector Machines, Random Forest



*στην οικογένειά μου*



## Ευχαριστίες

---

Θα ήθελα να ευχαριστήσω τον καθηγητή Κ. Γεώργιο Ματσόπουλο για την επίβλεψη αυτής της διπλωματικής εργασίας και για την ευκαιρία που μου έδωσε να την εκπονήσω στο εργαστήριο Εργαστήριο Βιοϊατρικής Τεχνολογίας. Επίσης ευχαριστώ τον Θεοδωρή Βαγενά για την εξαιρετική συνεργασία που είχαμε. Τέλος θα ήθελα να ευχαριστήσω τη σύζυγό μου Αντωνία και τα δύο μου παιδιά Χριστίνα και Αλέξανδρο για την υπομονή τους και την ηθική τους συμπαράσταση.

Αθήνα, Ιανουάριος 2023

*Παναγιώτης Κονταξής*



# Περιεχόμενα

---

<b>Περίληψη</b>	<b>1</b>
<b>Abstract</b>	<b>3</b>
<b>Ευχαριστίες</b>	<b>7</b>
<b>1 Εισαγωγή</b>	<b>17</b>
1.1 Ιδιοπαθής Σκολίωση . . . . .	17
1.1.1 Διάγνωση σκολίωσης . . . . .	17
1.1.2 Θεραπεία σκολίωσης . . . . .	19
1.2 Αντικείμενο της διπλωματικής . . . . .	19
1.3 Οργάνωση του τόμου . . . . .	19
<b>I Θεωρητικό Μέρος</b>	<b>21</b>
<b>2 Θεωρητικό υπόβαθρο</b>	<b>23</b>
2.1 Μηχανική Μάθηση . . . . .	23
2.1.1 Μέθοδοι Μηχανικής Μάθησης . . . . .	23
2.2 Συνήθεις αλγόριθμοι επιβλεπόμενης Μηχανικής Μάθησης . . . . .	24
2.3 Λογιστική Παλινδρόμηση . . . . .	25
2.4 Μηχανές Διανυσμάτων Υποστήριξης . . . . .	28
2.5 Τυχαίο Δάσος . . . . .	30
2.6 Μετρικές αξιολόγησης ταξινόμησης . . . . .	34
2.7 Εξαγωγή χαρακτηριστικών . . . . .	36
<b>3 Σχετικές εργασίες και συναφής βιβλιογραφία</b>	<b>37</b>
<b>II Πρακτικό Μέρος</b>	<b>41</b>
<b>4 Περιγραφή δεδομένων και εργαλείων</b>	<b>43</b>
4.1 Περιγραφή συνόλου δεδομένων . . . . .	43
4.2 Εργαλεία . . . . .	45
4.2.1 Pandas . . . . .	45
4.2.2 Numpy . . . . .	45
4.2.3 Math . . . . .	46
4.2.4 Matplotlib . . . . .	46

4.2.5 Seaborn . . . . .	46
4.2.6 scikit-learn . . . . .	46
4.2.7 OpenCV . . . . .	46
4.2.8 Shapely . . . . .	47
4.2.9 Mediarpipe . . . . .	47
<b>5 Επιλογή και εξαγωγή χαρακτηριστικών</b>	<b>49</b>
5.1 Επιλογή χαρακτηριστικών για την εκτίμηση της σκολίωσης . . . . .	49
<b>6 Εκπαίδευση και αξιολόγηση μοντέλων μηχανικής μάθησης</b>	<b>55</b>
6.1 Μοντέλο λογιστικής παλινδρόμησης . . . . .	55
6.2 Μοντέλο Μηχανών Διανυσμάτων Υποστήριξης . . . . .	58
6.3 Μοντέλο Τυχαίου Δάσους . . . . .	58
6.4 Σύγκριση μοντέλων . . . . .	59
6.4.1 Σύγκριση ακρίβειας μοντέλων . . . . .	60
6.4.2 Σύγκριση μοντέλων για την επιλογή χαρακτηριστικών . . . . .	61
6.4.3 Ποιοτική σύγκριση μοντέλων . . . . .	62
<b>III Επίλογος</b>	<b>65</b>
<b>7 Επίλογος</b>	<b>67</b>
7.1 Συμπεράσματα . . . . .	67
7.2 Μελλοντικές Επεκτάσεις . . . . .	68
<b>Βιβλιογραφία</b>	<b>72</b>
<b>Απόδοση ξενόγλωσσων όρων</b>	<b>73</b>



## Κατάλογος Σχημάτων

---

2.1	Το υπερεπίπεδο διαχωρισμού μέγιστου περιθωρίου στις Μηχανές Διανυσμάτων Υποστήριξης . . . . .	29
6.1	Διάγραμμα ροής εργασίας προεπεξεργασίας του συνόλου δεδομένων και εκπαίδευσης των μοντέλων Μηχανικής Μάθησης . . . . .	56
6.2	Διάγραμμα κατάταξης για τη σημαντικότητα των διαφορετικών χαρακτηριστικών στο μοντέλο της Λογιστικής Παλινδρόμησης . . . . .	62



## Κατάλογος Εικόνων

---

1.1	Δοκιμασία πρόσθιας κάμψης Adam και μέτρηση της περιστροφής του κορμού με τη χρήση σκολιόμετρου. . . . .	18
1.2	Τρόπος υπολογισμού της γωνίας Cobb. (πηγή: [1]) . . . . .	18
3.1	Εικόνα πλάτης ασθενή με τους οδηγούς των υπολογιζόμενων χαρακτηριστικών που λήφθηκε από τη δημοσίευση [2] . . . . .	38
3.2	Παράδειγμα φωτογραφιών που ελήφθησαν στη δημοσίευση [3] με τα υπολογιζόμενα μεγέθη . . . . .	39
4.1	Παράδειγμα εικόνας πλάτης ασθενών με σκολίωση που λήφθηκε από τη δημοσίευση [4] . . . . .	44
5.1	Δείγμα εικόνας του συνόλου δεδομένων πριν και μετά την επισήμανση των συντεταγμένων των σημείων του σώματος με τη βιβλιοθήκη mediapipe . . . . .	51
5.2	Εικόνα του συνόλου δεδομένων έπειτα από την επισήμανση των σημείων του σώματος από το μονέλο mediapipe και τον υπολογισμό των παράγωγων μεγεθών	52



## Κατάλογος Πινάκων

---

2.1	Πίνακας σύγχυσης μοντέλου δυαδικής ταξινόμησης. . . . .	34
4.1	Πλήθος παρατηρήσεων συνόλου δεδομένων με κατανομή στις επιμέρους κατηγορίες. . . . .	43
5.1	Το σύνολο δεδομένων κατόπιν της εξαγωγής των χαρακτηριστικών από τις εικόνες ασθενών με σκολίωση και υγιών ατόμων. . . . .	53
5.2	Το σύνολο δεδομένων κατόπιν της εξαγωγής των χαρακτηριστικών από τις εικόνες ασθενών με σκολίωση και υγιών ατόμων. (συνέχεια) . . . . .	53
6.1	Διαχωρισμός συνόλου δεδομένων σε δεδομένα εκπαίδευσης και ελέγχου του μοντέλου. . . . .	55
6.2	Πίνακας Σύγχυσης μοντέλου Λογιστικής Παλινδρόμησης. . . . .	57
6.3	Συγκεντρωτική αναφορά απόδοσης μοντέλου Λογιστικής Παλινδρόμησης. . .	57
6.4	Πίνακας σύγχυσης μοντέλου SVM. . . . .	58
6.5	Συγκεντρωτική αναφορά απόδοσης μοντέλου SVM. . . . .	58
6.6	Πίνακας σύγχυσης μοντέλου Τυχαίου Δάσους. . . . .	59
6.7	Συγκεντρωτική αναφορά απόδοσης μοντέλου Τυχαίου Δάσους. . . . .	59
6.8	Μετρικές αξιολόγησης των τριών μοντέλων που εκπαιδεύτηκαν. . . . .	60
6.9	Ποσοτική μέτρηση της συνεισφοράς των διαφορετικών χαρακτηριστικών στην προβλεπτική ικανότητα του μοντέλου του Τυχαίου Δάσους. . . . .	61



## Κεφάλαιο **1**

### Εισαγωγή

---

#### 1.1 Ιδιοπαθής Σκολίωση

**Η** σκολίωση είναι μια πάθηση που προκαλεί μη φυσιολογική καμπυλότητα της σπονδυλικής στήλης. Ο πιο κοινός τύπος σκολίωσης είναι η Ιδιοπαθής Σκολίωση και οφείλει την ονομασία της στην άγνωστη αιτία από την οποία προκαλείται. Η εξέλιξη της ιδιοπαθούς σκολίωσης ξεκινάει στο τέλος της παιδικής ηλικίας ή στην αρχή της εφηβείας και εξελίσσεται μέχρι ένα παιδί να ενηλικιωθεί.

Σε πολλές περιπτώσεις η καμπυλότητα της σπονδυλικής στήλης παραμένει σταθερή. Σε ορισμένα παιδιά όμως μπορεί να είναι προοδευτικά αυξανόμενη κάτι που σημαίνει ότι η πάθηση της σκολίωσης γίνεται πιο σοβαρή με την πάροδο του χρόνου. Η ήπια σκολίωση γενικά δεν προκαλεί πόνο, προβλήματα στην κίνηση ή δυσκολία στην αναπνοή. Ένα μικρό ποσοστό όμως των προσβεβλημένων παιδιών μπορεί να αναπτύξει μία πιο σοβαρή και έντονη καμπυλότητα της σπονδυλικής στήλης.


Στα συμπτώματα της σκολίωσης περιλαμβάνονται οι ανομοιομόρφοι ώμοι, η ανομοιομόρφη μέση, η διαφορά ύψους των ισχύων και σε κάποιες περιπτώσεις η μια ωμοπλάτη προεξέχει περισσότερο από την άλλη [5]. Οι ασθενείς με σκολίωση μπορεί να αντιμετωπίσουν δυσκολίες στην καθιστική θέση και την ορθοστασία, δυσκολίες στο περπάτημα λόγω απώλειας συντονισμού των μυών των ποδιών, δύσπνοια και κόπωση και προβλήματα νευρολογικής φύσης όπως αδυναμία, μούδιασμα και πόνο στα πόδια [6].

##### 1.1.1 Διάγνωση σκολίωσης

Σε πολλές περιπτώσεις η σκολίωση εντοπίζεται για πρώτη φορά κατά τη διάρκεια κάποιου σχολικού προληπτικού ελέγχου ή τακτικού παιδιατρικού ελέγχου. Εάν ο παιδίατρος υποψιάζεται την ύπαρξη σκολίωσης μπορεί να παραπέμψει το παιδί σε χειρούργο παιδοορθοπεδικό για πιο αναλυτική αξιολόγηση και την πρόταση ενός πλάνου θεραπείας.

Η σκολίωση μπορεί να ανιχνευθεί με ακρίβεια σε ασυμπτωματικούς εφήβους με διάφορες τεχνικές [7]. Η πρώτη τεχνική περιλαμβάνει τη δοκιμασία πρόσθιας κάμψης Adam που περιλαμβάνει, όπως φαίνεται και στην Εικόνα 1.1α, την επίκυψη του παιδιού προς τα μπροστά με τα πόδια ενωμένα, τα γόνατα ίσια και τα χέρια να κρέμονται ελεύθερα. Στη στάση αυτή ο ιατρός παρατηρεί την πλάτη του παιδιού για διαφορές μεταξύ των πλευρών του και για παραμόρφωση της σπονδυλικής στήλης η οποία είναι αρκετά ορατή στη θέση

αυτή. Με το παιδί να στέκεται όρθιο, ο γιατρός επίσης ελέγχει εάν τα ισχία και οι ώμοι είναι στο ίδιο επίπεδο και εάν η θέση του κεφαλιού είναι στο κέντρο πάνω από την ωμοπλάτη. Συχνά η παραπάνω εξέταση συνδυάζεται με τη χρήση σκολιόμετρου ενός εργαλείου που χρησιμοποιείται για τη μέτρηση της γωνίας περιστροφής του κορμού όπως φαίνεται στην εικόνα 1.1β. Η μέτρηση του σκολιόμετρου μπορεί να χρησιμοποιηθεί για την εκτίμηση της γωνίας Cobb, η οποία μετριέται με ακτινογραφία.




(α) Δοκιμασία πρόσθιας κάμψης Adam. (πηγή: [7])

(β) Μέτρηση της περιστροφής του κορμού με τη χρήση σκολιόμετρου. (πηγή: [7])

Εικόνα 1.1: Δοκιμασία πρόσθιας κάμψης Adam και μέτρηση της περιστροφής του κορμού με τη χρήση σκολιόμετρου.

Τέλος, η δοκιμασία πρόσθιας κάμψης Adam κάποιες φορές συνδυάζεται με την τοπογραφία Moiré η οποία περιλαμβάνει ένα εξειδικευμένο μηχάνημα που ανιχνεύει ανομοιομορφίες μεταξύ της δεξιάς και της αριστερής πλευράς της πλάτης του εξεταζόμενου.

Η γωνία Cobb χρησιμοποιείται ως τυπική μέτρηση για τον προσδιορισμό και την παρακολούθηση της εξέλιξης της σκολίωσης, και εφευρέθηκε από τον Dr John Cobb το 1948. Η γωνία Cobb είναι η γωνία που σχηματίζεται από τις ευθείες που περνούν από τον πιο κεκλιμένο σπόνδυλο στο επάνω μέρος της καμπύλης της σπονδυλικής στήλης και από τον πιο κεκλιμένο σπόνδυλο στο κάτω μέρος της καμπύλης [1]. Ο τρόπος υπολογισμού της φαίνεται στην Εικόνα 1.2.



Εικόνα 1.2: Τρόπος υπολογισμού της γωνίας Cobb. (πηγή: [1])



### 1.1.2 Θεραπεία σκολίωσης

Σε πολλές περιπτώσεις, στην σκολίωση η καμπυλότητα της σπονδυλικής στήλης είναι μικρή και δεν απαιτείται θεραπεία. Τα παιδιά με μεγαλύτερη καμπυλότητα μπορεί να χρειαστεί να φορέσουν ένα νάρθηκα ή να υποβληθούν σε χειρουργική επέμβαση για να αποκαταστήσουν τη φυσιολογική στάση του σώματος.

## 1.2 Αντικείμενο της διπλωματικής

Η έγκαιρη διάγνωση της σκολίωσης παίζει καθοριστικό ρόλο στη μετέπειτα εξέλιξη της νόσου αλλά και στην ποιότητα ζωής των ασθενών. Καθώς η σκολίωση επιδεινώνεται, αναπτύσσονται ψυχικά και σωματικά ζητήματα, όπως ο πόνος [8], αναπνευστικά προβλήματα [9] και η μειωμένη αυτοεκτίμηση [10].

Η πρόσβαση όλων των παιδιών σε ένα εργαλείο πρώιμης διάγνωσης της σκολίωσης είναι σημαντική καθώς η επίσκεψη σε παιδίατρο για τον προσυμπτωματικό έλεγχο μπορεί να μην είναι δυνατή. Ακόμη όμως και η εξέταση για τη σκολίωση από παιδίατρο μπορεί να είναι μια χρονοβόρα, αρκετά υποκειμενική διαδικασία, η οποία ενδεχομένως μπορεί να περιλαμβάνει τη λήψη ακτίνων X οι οποίες είναι επιβλαβείς, ειδικά για τα άτομα που βρίσκονται στο στάδιο της ανάπτυξης όπως είναι τα παιδιά. Μια εναλλακτική μεθοδολογική προσέγγιση θα μπορούσε να βελτιώσει σημαντικά τη διάγνωση καθώς και την ευημερία των παιδιών.

Σκοπός λοιπόν της διπλωματικής είναι η ανάπτυξη ενός εργαλείου το οποίο θα χρησιμοποιεί αλγόριθμους επεξεργασίας εικόνας και Μηχανικής Μάθησης με στόχο την εύκολη πρόσβαση όλων των παιδιών σε ένα προληπτικό έλεγχο για τη σκολίωση με χρήση μιας απλής φωτογραφίας της πλάτης τους.

## 1.3 Οργάνωση του τόμου

Η εργασία αυτή είναι οργανωμένη σε επτά κεφάλαια. Στο Κεφάλαιο 2 αναπτύσσεται το θεωρητικό υπόβαθρο των βασικών εννοιών της Μηχανικής Μάθησης και των μοντέλων δυαδική ταξινόμησης που χρησιμοποιήθηκαν δηλαδή της Λογιστικής Παλινδρόμησης των Μηχανών Διανυσμάτων Υποστήριξης και του Τυχαίου Δάσους. Στο ίδιο κεφάλαιο παρουσιάστηκαν οι μετρικές αξιολόγησης των μοντέλων δυαδικής ταξινόμησης με έμφαση σε αυτές που ήταν κατάλληλες για το πρόβλημα της διπλωματικής. Στο κεφάλαιο 3 παρουσιάζονται σχετικές εργασίες με το θέμα της διπλωματικής από τη διεθνή βιβλιογραφία που αφορούν την αναγνώριση σκολίωσης από φωτογραφίες δύο διαστάσεων. Στο Κεφάλαιο 4 περιγράφεται το σύνολο δεδομένων που δημιουργήθηκε για τις ανάγκες της διπλωματικής και παρουσιάζονται οι προγραμματιστικές βιβλιοθήκες που χρησιμοποιήθηκαν για την υλοποίηση των μοντέλων Μηχανικής Μάθησης. Στο Κεφάλαιο 5 παρουσιάζεται η διαδικασία επιλογής των χαρακτηριστικών από τις εικόνες και περιγράφεται αναλυτικά ο τρόπος εξαγωγής τους. Στο Κεφάλαιο 6 παρουσιάζονται τα αποτελέσματα της εκπαίδευσης και αναλύεται η προβλεπτική ικανότητα των μοντέλων της Λογιστικής Παλινδρόμησης, των Μηχανών Διανυσμάτων Υποστήριξης και του Τυχαίου Δάσους κάνοντας χρήση των μετρικών που παρουσιάστηκαν στο Κεφάλαιο 2. Κατόπιν πραγματοποιείται ποσοτική και ποιοτική σύγκριση των τριών

μοντέλων και σχολιάζεται πώς το καθένα ξεχωριστά προσαρμόζεται στα δεδομένα του προβλήματος. Τέλος, στο Κεφάλαιο 7 παρουσιάζονται τα συμπεράσματα της διπλωματικής και σχολιάζονται οι μελλοντικές επεκτάσεις που μπορούν να γίνουν.

## Μέρος I

### Θεωρητικό Μέρος

---



## Κεφάλαιο 2

### Θεωρητικό υπόβαθρο

---

Στο κεφάλαιο αυτό παρουσιάζονται αναλυτικά κάποιες θεωρητικές έννοιες για τη Μηχανική Μάθηση, οι αλγόριθμοι Μηχανικής Μάθησης που χρησιμοποιήθηκαν και εκπαιδεύτηκαν στη διπλωματική καθώς και οι μετρικές αξιολόγησης της απόδοσης των διαφορετικών μοντέλων.

#### 2.1 Μηχανική Μάθηση

Η Μηχανική Μάθηση είναι ένας κλάδος της τεχνητής νοημοσύνης (AI) και της επιστήμης των υπολογιστών που εστιάζει στη χρήση δεδομένων και αλγορίθμων για τη μίμηση του τρόπου με τον οποίο μαθαίνουν οι άνθρωποι. Οι αλγόριθμοι Μηχανικής Μάθησης χρησιμοποιούν συνήθως ιστορικά δεδομένα ως είσοδο για να προβλέψουν νέες τιμές εξόδου.

Με τη χρήση στατιστικών μεθόδων, οι αλγόριθμοι εκπαιδεύονται να κάνουν ταξινομήσεις ή προβλέψεις ή να ανακαλύπτουν νέα γνώση σε έργα εξόρυξης δεδομένων. Τα ευρήματα και οι προβλέψεις της Μηχανικής Μάθησης βοηθούν στη λήψη αποφάσεων με ιδιαίτερα θετικό αντίκτυπο στον τομέα που χρησιμοποιούνται.

Η Μηχανική Μάθηση περιλαμβάνει συνήθως τα ακόλουθα δομικά στοιχεία:

- Διαδικασία απόφασης: Με βάση τα δεδομένα εισόδου, τα οποία μπορούν να έχουν ετικέτα ή να είναι χωρίς ετικέτα, ο αλγόριθμος παράγει μια πρόβλεψη αξιοποιώντας τις στατιστικές ιδιότητες των δεδομένων.
- Συνάρτηση σφάλματος: Η συνάρτηση σφάλματος αξιολογεί την προβλεπτική ικανότητα και την ακρίβεια του μοντέλου συγκρίνοντας τις προβλέψεις του με την αντικειμενική αλήθεια.
- Διαδικασία βελτιστοποίησης μοντέλου: Με χρήση των δεδομένων εκπαίδευσης, τα βάρη του μοντέλου προσαρμόζονται έτσι ώστε να μειωθεί η απόκλιση μεταξύ της αντικειμενικής αλήθειας και της πρόβλεψης του μοντέλου. Ο αλγόριθμος επαναλαμβάνει αυτή τη διαδικασία «αξιολόγησης και βελτιστοποίησης», ενημερώνοντας τα βάρη έως ότου επιτευχθεί ένα όριο ακρίβειας.

##### 2.1.1 Μέθοδοι Μηχανικής Μάθησης

Τα μοντέλα Μηχανικής Μάθησης ταξινομούνται σε τρεις κύριες κατηγορίες:

### **Επιβλεπόμενη μηχανική εκμάθηση**

Η επιβλεπόμενη Μηχανική Μάθηση (Supervised learning), ορίζεται από τη χρήση συνόλων δεδομένων με ετικέτες για την εκπαίδευση αλγορίθμων για την ταξινόμηση δεδομένων ή την ακριβή πρόβλεψη ενός μεγέθους. Καθώς τα δεδομένα εισόδου τροφοδοτούνται στο μοντέλο, το μοντέλο προσαρμόζει τα βάρη του μέχρι να επιτευχθεί η ζητούμενη ακρίβεια. Ορισμένες μέθοδοι που χρησιμοποιούνται στην επιβλεπόμενη Μηχανική Μάθηση περιλαμβάνουν τα νευρωνικά δίκτυα, τη μέθοδο *naive Bayes*, τη γραμμική παλινδρόμηση, τις Μηχανές Διανυσμάτων Υποστήριξης, την Λογιστική Παλινδρόμηση, τη μέθοδο *Random Forest* κ.λπ.

### **Μη επιβλεπόμενη μηχανική μάθηση**

Η μη επιβλεπόμενη μηχανική μάθηση (Unsupervised learning), χρησιμοποιεί αλγόριθμους μηχανικής μάθησης για την ανάλυση και την ομαδοποίηση συνόλων δεδομένων χωρίς ετικέτα. Αυτοί οι αλγόριθμοι ανακαλύπτουν κρυφά μοτίβα ή ομαδοποιήσεις δεδομένων χωρίς την ανάγκη ανθρώπινης παρέμβασης όπως ο αλγόριθμος ομαδοποίησης *k-means*. Καποιοι άλλοι αλγόριθμοι χρησιμοποιούνται για τη μείωση του αριθμού των χαρακτηριστικών σε ένα μοντέλο μέσω της διαδικασίας μείωσης διαστάσεων. Ο αλγόριθμος *Principal Component Analysis* ή *PCA*) και ο *Singular value decomposition* ή *SVD* είναι δύο κοινές προσεγγίσεις στον τομέα αυτό.

### **Ενισχυτική μάθηση**

Η Ενισχυτική Μάθηση (*Reinforcement Learning*) είναι ένας κλάδος της Μηχανικής Μάθησης που ασχολείται με το πώς ευφυείς πράκτορες πρέπει να προχωρούν σε ενέργειες σε ένα άγνωστο περιβάλλον προκειμένου να μεγιστοποιήσουν την ανταμοιβή τους. Το σύνολο δεδομένων στην Ενισχυτική Μάθηση χρησιμοποιεί ένα σύστημα ανταμοιβών και τιμωριών, προσφέροντας ανατροφοδότηση στον αλγόριθμο για να μάθει από τις δικές του εμπειρίες πραγματοποιώντας δοκιμές και μετρώντας τα σφάλματα.

## **2.2 Συνήθεις αλγόριθμοι επιβλεπόμενης Μηχανικής Μάθησης**

### **Γραμμική Παλινδρόμηση (Linear Regression)**

Η γραμμική παλινδρόμηση χρησιμοποιείται για την ανάλυση της σχέσης μεταξύ ανεξάρτητων μεταβλητών εισόδου και τουλάχιστον μίας μεταβλητής στόχου. Αυτό το είδος παλινδρόμησης χρησιμοποιείται για την πρόβλεψη μεταβλητών που λαμβάνουν συνεχείς τιμές σε ένα αριθμητικό διάστημα.

### **Λογιστική Παλινδρόμηση (Logistic Regression)**

Η Λογιστική Παλινδρόμηση είναι ένας αλγόριθμος επιβλεπόμενης μάθησης που χρησιμοποιείται για προβλήματα ταξινόμησης. Αντί για συνεχή έξοδο όπως στη γραμμική παλινδρόμηση, η λογιστική παλινδρόμηση προβλέπει την πιθανότητα να συμβεί ένα δυαδικό γεγονός (ΝΑΙ/ΟΧΙ). Η Λογιστική Παλινδρόμηση χρησιμοποιήθηκε στην διπλωματική για την ταξινόμηση των εικόνων σε αυτές με ή χωρίς σκολίωση και για τον λόγο αυτό θα αναλυθεί περισσότερο σε επόμενη ενότητα.

### **Νευρωνικά Δίκτυα (Neural Networks)**

Τα Νευρωνικά Δίκτυα προσομοιώνουν τον τρόπο που λειτουργεί ο ανθρώπινος εγκέφαλος, με έναν πολύ μεγάλο αριθμό συνδεδεμένων κόμβων επεξεργασίας. Τα νευρωνικά δίκτυα τροφοδοτούνται στους νευρώνες εισόδου με τις τιμές των χαρακτηριστικών του μοντέλου και δίνουν στην έξοδό τους την επιθυμητή τιμή. Κατά τη διαδικασία εκπαίδευσης καθορίζονται οι τιμές των βαρών που συνδέουν τους κόμβους έτσι ώστε να δίνουν στην έξοδο την επιθυμητή πρόβλεψη. Παίζουν σημαντικό ρόλο σε εφαρμογές όπως η επεξεργασία φυσικής γλώσσας, η αναγνώριση εικόνας, η αναγνώριση ομιλίας και η δημιουργία εικόνων.

### **Δένδρα Αποφάσεων (Decision Trees)**

Τα Δέντρα Αποφάσεων μπορούν να χρησιμοποιηθούν τόσο για την πρόβλεψη αριθμητικών τιμών (παλινδρόμηση) όσο και για την ταξινόμηση δεδομένων σε κατηγορίες. Τα δέντρα αποφάσεων χρησιμοποιούν μια διακλαδούμενη ακολουθία συνδεδεμένων κόμβων απόφασης που μπορούν να αναπαρασταθούν σε ένα δενδρικό διάγραμμα. Ένα από τα πλεονεκτήματα των δέντρων αποφάσεων είναι ότι είναι εύκολο να επικυρωθούν και να ελεγχθούν, σε αντίθεση με το μαύρο κουτί του νευρωνικού δικτύου. Επομένως χρησιμοποιούνται αρκετά για την εξαγωγή γνώσης από δεδομένα.

### **Τυχαίο δάσος (Random Forest)**

Το μοντέλο του Τυχαίου Δάσους ταξινομεί δεδομένα χρησιμοποιώντας μια ποικιλία μοντέλων δέντρων αποφάσεων ταυτόχρονα. Όπως συμβαίνει και με τα δέντρα απόφασης, τα μοντέλα τυχαίου δάσους μπορούν να χρησιμοποιηθούν για τον προσδιορισμό της ταξινόμησης κατηγορικών μεταβλητών ή της παλινδρόμησης συνεχών μεταβλητών. Ένα μοντέλο Τυχαίου Δάσους δημιουργεί έναν αριθμό δέντρων αποφάσεων όπως καθορίζονται από τον χρήστη, σχηματίζοντας αυτό που είναι γνωστό ως σύνολο (ensemble). Στη συνέχεια, κάθε δέντρο απόφασης κάνει τη δική του πρόβλεψη με βάση κάποια δεδομένα εισόδου και ο αλγόριθμος του τυχαίου δάσους κάνει μια πρόβλεψη συνδυάζοντας τις προβλέψεις κάθε επιμέρους Δένδρου Απόφασης στο σύνολο.

### **Μηχανές Διανυσμάτων Υποστήριξης (Support Vector Machines)**

Το μοντέλο των Μηχανών Διανυσμάτων Υποστήριξης χρησιμοποιείται συνήθως σε προβλήματα ταξινόμησης. Στόχος του αλγορίθμου αυτού είναι να υπολογίσει ένα υπερεπίπεδο σε ένα χώρο πολλών διαστάσεων το οποίο να ταξινομεί τις παρατηρήσεις του συνόλου δεδομένων και να μεγιστοποιεί το περιθώριο μεταξύ του υπερεπίπεδου διαχωρισμού και των ακραίων παρατηρήσεων των διαφορετικών κατηγοριών.

## **2.3 Λογιστική Παλινδρόμηση**

Η Λογιστική Παλινδρόμηση είναι ένας αλγόριθμος επιβλεπόμενης μάθησης. Χρησιμοποιείται για τον υπολογισμό ή την πρόβλεψη της πιθανότητας να συμβεί ένα δυαδικό (ΝΑΙ/ΟΧΙ) γεγονός, πραγματοποιώντας κάποια πρόβλεψη με βάση τις ανεξάρτητες μεταβλητές (X) των δεδομένων. Η Λογιστική Παλινδρόμηση βρίσκει εφαρμογή σε τομείς όπως η υγεία και απαντάει σε ερωτήσεις του τύπου αν ένας όγκος είναι κακοήθης ή όχι, στην οικονομία εάν

μία συναλλαγή είναι ύποπτη ή όχι και στο marketing αν ένα συγκεκριμένο κοινό πρόκειται να απαντήσει σε μία καμπάνια προώθησης ή όχι.

Σε ένα πρόβλημα Λογιστικής Παλινδρόμησης ορίζουμε ως  $Y$  την εξαρτημένη μεταβλητή ή πρόβλεψη και ως  $X$  την ανεξάρτητη μεταβλητή. Για να μοντελοποιήσουμε τη σχέση της πιθανότητας να συμβεί το ενδεχόμενο  $Y$  ως προς την ανεξάρτητη μεταβλητή  $X$  μπορούμε να χρησιμοποιήσουμε την ακόλουθη σχέση:

$$p(X) = Pr(Y = 1|X) \quad (2.1)$$

Στην γραμμική παλινδρόμηση ορίζουμε την παραπάνω σχέση ως εξής

$$p(X) = b_0 + b_1 X. \quad (2.2)$$

Αντίστοιχα, στη λογιστική παλινδρόμηση για να αποφύγουμε το ενδεχόμενο η πιθανότητα να λάβει αρνητικές τιμές ή τιμές μεγαλύτερες του 1 ορίζουμε τη **Λογιστική Συνάρτηση** ως εξής:

$$p(X) = \frac{e^{b_0+b_1X}}{1 + e^{b_0+b_1X}} \quad (2.3)$$

Για να προσαρμόσουμε το μοντέλο της σχέσης 2.3 χρησιμοποιούμε τη μέθοδο της μέγιστης πιθανοφάνειας. Η Λογιστική Συνάρτηση παράγει πάντα μια καμπύλη σχήματος S, και έτσι ανεξάρτητα από την τιμή του  $X$ , θα έχουμε μια λογική πρόβλεψη 0 η 1. Στην τελευταία σχέση η πιθανότητα  $p(X)$  δε λαμβάνει τιμές κάτω του 0 ή άνω του 1. Με πράξεις καταλήγουμε στην παρακάτω σχέση:

$$\frac{p(X)}{1 - p(X)} = e^{b_0+b_1X} \quad (2.4)$$

Η ποσότητα  $\frac{p(X)}{1-p(X)}$  ονομάζεται **odds** και μπορεί να πάρει οποιαδήποτε τιμή μεταξύ 0 και  $\infty$ . Μία τιμή κοντά στο 0 και το  $\infty$  δείχνει πολύ χαμηλή και πολύ υψηλή πιθανότητα να συμβεί το γεγονός, αντίστοιχα. Για παράδειγμα αν η πιθανότητα να συμβεί ένα γεγονός είναι 20% ο λόγος odds είναι  $\frac{0.2}{1-0.2} = 4$ .

Λογαριθμώντας την τελευταία σχέση λαμβάνουμε:

$$\log\left(\frac{p(X)}{1 - p(X)}\right) = b_0 + b_1 X \quad (2.5)$$

Το αριστερό μέρος της παραπάνω συνάρτησης ονομάζεται **log odds** ή **logit**, και παρέχει μία φυσική ερμηνεία της λογιστικής παλινδρόμησης. Όταν η τιμή του  $X$  αυξάνει κατά μία μονάδα τότε ο λόγος log odds αυξάνει κατά  $b_1$ . Αντίστοιχα ο λόγος odds πολλαπλασιάζεται με την ποσότητα  $e^{b_1}$ . Η ποσότητα που αλλάζει το  $p(X)$  λόγω αλλαγής μιας μονάδας στο  $X$  εξαρτάται από την τρέχουσα τιμή του  $X$ .

Οι συντελεστές  $b_0$  και  $b_1$  στη σχέση 2.3 είναι άγνωστοι και εκτιμούνται με βάση τα διαθέσιμα δεδομένα εκπαίδευσης. Για την εκτίμηση των συντελεστών αυτών χρησιμοποιείται η συνάρτηση της μέγιστης πιθανοφάνειας. Σύμφωνα με τη συνάρτηση αυτή αναζητούνται εκτιμήσεις για τα  $b_0$  και  $b_1$  έτσι ώστε η προβλεπόμενη πιθανότητα  $p(\hat{x}_i)$  για κάθε παρατήρηση, χρησιμοποιώντας τη σχέση 2.3, να αντιστοιχεί όσο το δυνατόν πιο κοντά στην αντικειμενική



αλήθεια. Μαθηματικά η **Συνάρτηση Μέγιστης Πιθανοφάνειας** ορίζεται ως εξής:

$$l(b_0, b_1) = \prod_{i:y_i=1} p(x_i) \prod_{i':y_{i'}=0} (1 - p(x_{i'})) \quad (2.6)$$

Οι συντελεστές  $\hat{b}_0$  και  $\hat{b}_1$  επιλέγονται έτσι ώστε να μεγιστοποιηθεί η παραπάνω συνάρτηση πιθανοφάνειας.

Στην Λογιστική παλινδρόμηση με περισσότερες από μία ανεξάρτητες μεταβλητές γίνεται πρόβλεψη της ανεξάρτητης μεταβλητής  $Y$  με βάση περισσότερες από μία ανεξάρτητες μεταβλητές. Στην περίπτωση η σχέση 2.5 γενικεύεται ως εξής:

$$\log\left(\frac{p(X)}{1 - p(X)}\right) = b_0 + b_1X_1 + \dots + b_pX_p \quad (2.7)$$

όπου  $X = (X_1, \dots, X_p)$  είναι οι  $p$  μεταβλητές πρόβλεψης. Η σχέση 2.7 μπορεί να ξαναγραφεί ως:

$$p(X) = \frac{e^{b_0 + b_1X_1 + \dots + b_pX_p}}{1 + e^{b_0 + b_1X_1 + \dots + b_pX_p}} \quad (2.8)$$

οπότε αντίστοιχα χρησιμοποιώντας τη συνάρτηση μέγιστης πιθανοφάνειας γίνεται εκτίμηση των συντελεστών  $b_0, b_1, \dots, b_p$

Σύμφωνα με την [11] για να λειτουργήσει ορθά η λογιστική παλινδρόμηση υπάρχει ένα πλήθος παραδοχών που πρέπει να επαληθεύονται:

1. Η εξαρτημένη μεταβλητή να λαμβάνει τιμές που είναι κατάλληλες για την λογιστική παλινδρόμηση δηλαδή 1 ή 0 που αντιστοιχεί σε Ναι/Όχι.
2. Η σχέση μεταξύ της συνάρτησης logit (η αλλιώς log-odds) του αποτελέσματος και κάθε συνεχούς ανεξάρτητης μεταβλητής να είναι γραμμική.
3. Η λογιστική παλινδρόμηση προϋποθέτει ότι δεν υπάρχουν ακραία (outliers) σημεία δεδομένων με μεγάλη επιρροή, καθώς παραμορφώνουν το αποτέλεσμα και την ακρίβεια του μοντέλου. Συνεπώς είναι χρήσιμο να ελεγχθεί αν μία παρατήρηση είναι ταυτόχρονα και ακραία αλλά και ασκεί υψηλή επιρροή.
4. Εάν υπάρχει πολυσυγγραμμικότητα μεταξύ των ανεξάρτητων μεταβλητών, δηλαδή να υπάρχει υψηλή συσχέτιση μεταξύ τους, μειώνεται η ακρίβεια των εκτιμώμενων συντελεστών, γεγονός που αποδυναμώνει τη στατιστική ισχύ του μοντέλου λογιστικής παλινδρόμησης.
5. Οι παρατηρήσεις πρέπει να είναι ανεξάρτητες η μία από την άλλη, δηλαδή να μην προέρχονται από επαναλαμβανόμενα δεδομένα. Αυτό σημαίνει ότι κάθε παρατήρηση δεν επηρεάζεται ούτε σχετίζεται με τις υπόλοιπες παρατηρήσεις.
6. Θα πρέπει να υπάρχει επαρκής αριθμός παρατηρήσεων για κάθε ανεξάρτητη μεταβλητή στο σύνολο δεδομένων έτσι να αποφευχθεί η δημιουργία ενός μοντέλου το οποίο πάσχει από υπερπροσαρμογή, δηλαδή προσαρμόζεται υπερβολικά στα δεδομένα εκπαίδευσης αλλά αδυνατεί να δώσει σωστές προβλέψεις σε νέα άγνωστα δεδομένα.

## 2.4 Μηχανές Διανυσμάτων Υποστήριξης

Οι Μηχανές Διανυσμάτων Υποστήριξης (Support Vector Machine ή SVM) είναι μια προσέγγιση ταξινόμησης που αναπτύχθηκε τη δεκαετία του 1990. Ο στόχος του αλγόριθμου SVM είναι να βρει ένα υπερεπίπεδο σε ένα χώρο  $p$ -διαστάσεων (όπου  $p$  το πλήθος των χαρακτηριστικών) που ταξινομεί ευδιάκριτα τα σημεία δεδομένων. Για να διαχωριστούν δύο κατηγορίες σημείων δεδομένων, υπάρχουν πολλά πιθανά υπερεπίπεδα που θα μπορούσαν να επιλεγθούν. Στόχος του αλγόριθμου SVM είναι να βρεθεί το υπερεπίπεδο που παρέχει το μέγιστο περιθώριο, δηλαδή τη μέγιστη απόσταση μεταξύ των σημείων δεδομένων των δύο κατηγοριών. Η μεγιστοποίηση της απόστασης περιθωρίου παρέχει μεγαλύτερη βεβαιότητα, έτσι ώστε τα μελλοντικά σημεία δεδομένων να μπορούν να ταξινομηθούν με μεγαλύτερη ακρίβεια στη σωστή κατηγορία.

Έστω η συνάρτηση που περιγράφει ένα υπερεπίπεδο σε ένα χώρο διαστάσεων  $p$ :

$$b_0 + b_1X_1 + b_2X_2 + \dots + b_pX_p = 0 \quad (2.9)$$

Έστω πίνακας  $\mathbf{X}$  διαστάσεων  $n \times p$  που περιλαμβάνει  $n$  παρατηρήσεις εκπαίδευσης σε ένα χώρο διαστάσεων μεγέθους  $p$ :

$$x_1 = \begin{pmatrix} x_{11} \\ \dots \\ x_{1p} \end{pmatrix}, \dots, x_n = \begin{pmatrix} x_{n1} \\ \dots \\ x_{np} \end{pmatrix} \quad (2.10)$$

και όλες οι παρατηρήσεις εμπίπτουν σε μία από δύο κατηγορίες  $y_1, \dots, y_n \in \{-1, 1\}$  όπου το  $-1$  αναπαριστά την μία κατηγορία και το  $1$  την άλλη κατηγορία. Στόχος είναι ο ταξινομητής να ταξινομεί σωστά κάθε παρατήρηση ελέγχου χρησιμοποιώντας τα χαρακτηριστικά της. Τότε η συνάρτηση ενός υπερεπίπεδου που διαχωρίζει τις δύο κατηγορίες πρέπει να ικανοποιεί τις ακόλουθες δύο σχέσεις:

$$b_0 + b_1x_{i1} + b_2x_{i2} + \dots + b_px_{ip} > 0 \text{ εαν } y_i = 1 \quad (2.11)$$


$$b_0 + b_1x_{i1} + b_2x_{i2} + \dots + b_px_{ip} < 0 \text{ εαν } y_i = -1 \quad (2.12)$$

για κάθε  $i = 1, \dots, n$ .

Έτσι για να γίνει ταξινόμηση μίας παρατήρησης ελέγχου  $x^*$ , υπολογίζεται η ποσότητα  $f(x^*) = b_0 + b_1x_1^* + b_2x_2^* + \dots + b_px_p^*$ . Εάν η ποσότητα  $f(x^*)$  είναι θετική τότε η παρατήρηση αντιστοιχίζεται στην κλάση  $1$  αλλιώς αν είναι αρνητική αντιστοιχίζεται στην κλάση  $-1$ . Η απόλυτη τιμή της ποσότητας  $f(x^*)$  παίζει ρόλο, καθώς αν είναι μεγάλη σημαίνει ότι η παρατήρηση απέχει αρκετά από το υπερεπίπεδο που διαχωρίζει τις παρατηρήσεις, επομένως με μεγαλύτερη σιγουριά μπορεί να γίνει η αντιστοίχιση στην κατηγορία.

Πρακτικά υπάρχουν πολλά υπερεπίπεδα που μπορούν να ταξινομήσουν τις παρατηρήσεις. Η καλύτερη επιλογή όμως είναι το υπερεπίπεδο που δίνει μέγιστο περιθώριο ανάμεσα στις ακραίες παρατηρήσεις εκπαίδευσης των διαφορετικών κλάσεων. Αυτό το υπερεπίπεδο ονομάζεται ταξινομητής μέγιστου περιθωρίου και επειδή εξασφαλίζει μεγάλο περιθώριο στα

δεδομένα της εκπαίδευσης μάλλον θα παρέχει το ίδιο μεγάλο περιθώριο στα δεδομένα ελέγχου και ως εκ τούτου θα ταξινομήσει πιο σωστά τις παρατηρήσεις στο στάδιο του ελέγχου. Βέβαια εάν το  $p$ , δηλαδή ο χώρος των διαστάσεων των χαρακτηριστικών, είναι μεγάλος τότε υπάρχει ο κίνδυνος το μοντέλο να αντιμετωπίσει το φαινόμενο της υπερπροσαρμογής.



Σχήμα 2.1: Το υπερεπίπεδο διαχωρισμού μέγιστου περιθωρίου στις Μηχανές Διανυσμάτων Υποστήριξης.

Στο Σχήμα 2.1, τρεις παρατηρήσεις εκπαίδευσης βρίσκονται σε ίση απόσταση από το υπερεπίπεδο μέγιστου περιθωρίου και κατά μήκος των διακεκομμένων γραμμών υποδεικνύοντας το πλάτος του περιθωρίου. Αυτές οι τρεις παρατηρήσεις στο μοντέλο SVM ονομάζονται διανύσματα υποστήριξης.

Κατά την εκπαίδευση ενός μοντέλου SVM ο αλγόριθμος καλείται να υπολογίσει τους συντελεστές  $b_0, b_1, \dots, b_p$  έτσι ώστε να μεγιστοποιείται η απόσταση  $M$  στην ανίσωση:

$$y_i(b_0 + b_1x_{i1} + b_2x_{i2} + \dots + b_px_{ip}) \geq M \quad \forall i = 1, \dots, n \quad (2.13)$$

Όταν το μοντέλο της μηχανής διανυσμάτων υποστήριξης χρησιμοποιείται στην πράξη για την ταξινόμηση τις περισσότερες φορές μπορεί να μην υπάρχει ένα υπερεπίπεδο που διαχωρίζει τέλεια τις δύο κατηγορίες. Σε αυτή την περίπτωση ενδιαφέρει ο εντοπισμός ενός

υπερεπιπέδου που ταξινομεί καλύτερα τις περισσότερες από τις παρατηρήσεις εκπαίδευσης, με την παραχώρηση ότι κάποιες από τις παρατηρήσεις της εκπαίδευσης δε θα ταξινομηθούν σωστά. Σε αυτή την περίπτωση το μοντέλο καλείται να λύσει ένα πρόβλημα βελτιστοποίησης έτσι ώστε να ικανοποιούνται οι ακόλουθες σχέσεις:

$$\text{maximize } M \quad (2.14)$$

$$\sum_{j=1}^p b_j^2 = 1 \quad (2.15)$$

$$y_i(b_0 + b_1x_{i1} + b_2x_{i2} + \dots + b_px_{ip}) \geq M(1 - \epsilon_i) \quad (2.16)$$

$$\epsilon_i \geq 0, \sum_{i=1}^n \epsilon_i \leq C \quad (2.17)$$

όπου το  $C$  είναι μία μη αρνητική παράμετρος, το  $M$  είναι το πλάτος του διαστήματος διαχωρισμού και είναι επιθυμητή η μεγιστοποίηση του, και τα  $\epsilon_1, \dots, \epsilon_n$  είναι μεταβλητές που επιτρέπουν σε μεμονωμένες παρατηρήσεις να βρίσκονται στη λάθος πλευρά του υπερεπιπέδου. Αν  $\epsilon_i = 0$  τότε η  $i$ -οστή παρατήρηση βρίσκεται στη σωστή μεριά του υπερεπιπέδου, εάν  $\epsilon_i > 0$  τότε η  $i$ -οστή παρατήρηση βρίσκεται στη λανθασμένη μεριά του υπερεπιπέδου αλλά μέσα στα περιθώρια υποστήριξης και εάν  $\epsilon_i > 1$  τότε η  $i$ -οστή παρατήρηση βρίσκεται στη λανθασμένη μεριά του υπερεπιπέδου και έξω από τα περιθώρια υποστήριξης.

Το  $C$  δεσμεύει το άθροισμα των  $\epsilon_i$  οπότε καθορίζει το πλήθος και τη σοβαρότητα των παραβιάσεων στο περιθώριο (και στο υπερεπίπεδο) που θα δεχθούμε στο μοντέλο. Υψηλό  $C$  επιτρέπει μεγάλο πλήθος παραβιάσεων, ενώ χαμηλό  $C$  επιτρέπει μικρό πλήθος παραβιάσεων. Στην πράξη το  $C$  θεωρείται παράμετρος του μοντέλου και συχνά επιλέγεται με τη μέθοδο της διασταυρούμενης επικύρωσης (cross validation). Εκφράζει τον συμβιβασμό μεροληψίας-διακύμανσης (bias-variance trade-off). Όταν το  $C$  είναι μικρό, γίνεται αναζήτηση στενών περιθωρίων που σπάνια παραβιάζονται και οδηγεί σε έναν ταξινομητή που ταιριάζει πολύ στα δεδομένα, ο οποίος μπορεί να έχει χαμηλή προκατάληψη αλλά υψηλή διακύμανση. Όταν το  $C$  είναι μεγαλύτερο, το περιθώριο είναι μεγαλύτερο και επιτρέπονται περισσότερες παραβιάσεις σε αυτό. Αυτό ισοδυναμεί με λιγότερο αυστηρή προσαρμογή των δεδομένων και έναν ταξινομητή που είναι δυνητικά πιο προκατειλημμένος αλλά μπορεί να έχει μικρότερη διακύμανση.

Κάποιες φορές τα δεδομένα μπορεί να μην είναι γραμμικά διαχωρίσιμα. Στην περίπτωση αυτή δεν αρκεί ένα υπερεπίπεδο για να χωρίσει τα δεδομένα. Στην περίπτωση αυτή το μοντέλο των Μηχανών Διανυσμάτων Υποστήριξης (SVM) λειτουργεί ως επέκταση του απλού Ταξινομητή Διανυσμάτων Υποστήριξης καθώς μεγεθύνουν τον χώρο των χαρακτηριστικών με χρήση πυρήνων (kernels), έτσι ώστε αυτά να καταστούν γραμμικά διαχωρίσιμα.

## 2.5 Τυχαίο Δάσος

Το μοντέλο του Τυχαίου Δάσους (Random Forest) βασίζεται στο μοντέλο των Δένδρων Απόφασης (Decision Trees). Πολλά διαφορετικά Δένδρα Απόφασης εκπαιδεύονται και ψη-

φίζουν για το αποτέλεσμα και ως τελική πρόβλεψη λαμβάνεται αυτή που συγκεντρώνει τις περισσότερες ψήφους. Η μέθοδος αυτή ονομάζεται ensemble.

Τα Δέντρα Απόφασης βρίσκουν εφαρμογή και σε προβλήματα ταξινόμησης, όπως αυτό που πραγματεύεται η παρούσα διπλωματική. Ένα δέντρο αποφάσεων είναι ένα μοντέλο που αποτελείται από μια συλλογή ερωτήσεων οργανωμένων ιεραρχικά σε σχήμα δέντρου. Κάθε κόμβος-ερώτηση έχει δύο κόμβους-παιδιά που με τη σειρά τους να είναι είτε κόμβοι ερωτήσεων που περιλαμβάνουν μία νέα συνθήκη είτε κόμβοι φύλλων που περιλαμβάνουν μια πρόβλεψη.

Το συμπέρασμα ενός δέντρου απόφασης υπολογίζεται δρομολογώντας μία παρατήρηση από τη ρίζα του δέντρου μέχρι έναν από τους κόμβους-φύλλα σύμφωνα με τις συνθήκες των κόμβων-ερωτήσεων. Η τιμή του φύλλου που στο οποίο καταλήγει η παρατήρηση με βάση τα χαρακτηριστικά της αποτελεί την πρόβλεψη του Δέντρου Αποφάσεων. Το σύνολο των κόμβων που επισκέφθηκε η παρατήρηση στη διαδρομή της ονομάζεται διαδρομή συμπερασμάτων (inference path). Ένα Δέντρο Αποφάσεων που χρησιμοποιείται για ταξινόμηση περιλαμβάνει σε κάθε κόμβο-φύλλο μία κατηγορία από τις διαθέσιμες κατηγορίες πρόβλεψης.

Για την κατασκευή ενός δέντρου αποφάσεων για ταξινόμηση χρησιμοποιείται ο αλγόριθμος CART ο οποίος προκύπτει από τα αρχικά του ακρωνύμιου Classification and Regression Tree. Στον αλγόριθμο αυτό γίνεται εκκίνηση από τον κόμβο της ρίζας όπου πραγματοποιείται μια ερώτηση και με βάση την απάντηση (Ναι/Όχι), χωρίζεται περαιτέρω το δέντρο σε υποδέντρα.

Ο αλγόριθμος CART περιλαμβάνει τα ακόλουθα βήματα:

---

#### ΑΛΓΟΡΙΘΜΟΣ 2.1: Αλγόριθμος CART

---

1. Το δέντρο ξεκινάει με έναν ριζικό κόμβο, έστω  $S$ , ο οποίος περιέχει το πλήρες σύνολο δεδομένων.
  2. Εντοπίζεται το καλύτερο χαρακτηριστικό του συνόλου δεδομένων με χρήση της μετρικής χαρακτηριστικών Attribute Selection Measure (ASM).
  3. Διαιρείται το  $S$  σε υποσύνολα που περιέχουν πιθανές τιμές πιθανές τιμές για τα καλύτερα χαρακτηριστικά.
  4. Δημιουργείται ένας κόμβο απόφασης, ο οποίος περιέχει το καλύτερο χαρακτηριστικό.
  5. Δημιουργούνται αναδρομικά νέα δέντρα αποφάσεων χρησιμοποιώντας τα υποσύνολα του συνόλου δεδομένων που δημιουργήθηκαν στο βήμα 3. Συνεχίζεται η διαδικασία μέχρι να καταλήξει σε μία κατάσταση όπου δεν μπορούν να ταξινομηθούν περαιτέρω οι κόμβοι, οπότε ο τελικός αυτός κόμβος καλείται κόμβος-φύλλο.
- 

Για την επιλογή του καλύτερου χαρακτηριστικού για τον ριζικό κόμβο και για τους υποκόμβους χρησιμοποιούνται οι ακόλουθες δύο μετρικές:

1. Information Gain
2. Gini Index

Η μετρική Information Gain ποσοτικοποιεί τις αλλαγές στην εντροπία έπειτα από το διαχωρισμό του συνόλου δεδομένων με βάση ένα χαρακτηριστικό. Στόχος είναι η μεγιστοποίηση της τιμής του Information Gain και ένας κόμβος/χαρακτηριστικό που έχει το υψηλότερη τιμή στον δείκτη αυτό διαχωρίζεται πρώτα. Η μετρική Information Gain ποσοτικοποιεί τις αλλαγές στην εντροπία έπειτα από το διαχωρισμό του συνόλου δεδομένων με βάση ένα χαρακτηριστικό, και πρακτικά υπολογίζει το ποσό πληροφορίας που παρέχει ένα χαρακτηριστικό για μια κατηγορία. Μπορεί να υπολογιστεί αν από την εντροπία πριν τον διαχωρισμό γίνει αφαίρεση της εντροπίας μετά το διαχωρισμό σύμφωνα με τη σχέση  $Information\ Gain = Entropy(S) - [(Weighted\ Avg) * Entropy(each\ feature)]$ . Αυτό σημαίνει ότι όσο πιο μεγάλη είναι η τιμή του μεγέθους Information Gain τόσο περισσότερη εντροπία αφαιρείται από το σύνολο δεδομένων, εάν πραγματοποιηθεί ο συγκεκριμένος διαχωρισμός.

Η εντροπία ενός συνόλου δεδομένων υπολογίζεται από τον ακόλουθο τύπο

$$E = - \sum_i^c p_i \log_2 p_i \quad (2.18)$$

όπου  $p_i$  είναι η πιθανότητα τυχαίας επιλογής μία παρατήρησης της κλάσης  $i$ .

Αντίστοιχα η μετρική Gini Index είναι ένα μέτρο της ανομοιογένειας και χρησιμοποιείται κατά τη δημιουργία του δέντρου. Έχει τιμή μεταξύ 0 και 1. Τιμή του δείκτη Gini=0 σημαίνει ότι το δείγμα είναι απολύτως ομοιογενές και όλα τα στοιχεία του είναι παρόμοια, ενώ τιμή του δείκτη Gini=1 σημαίνει τη μέγιστη ανομοιογένεια μεταξύ των στοιχείων. Ένα χαρακτηριστικό με χαμηλό δείκτη Gini προτιμάται σε σύγκριση με ένα χαρακτηριστικό με υψηλό δείκτη Gini. Ο δείκτης Gini υπολογίζεται από τον παρακάτω τύπο:

$$Gini\ Index = 1 - \sum_{i=1}^n p_i^2 \quad (2.19)$$

όπου  $i$  είναι το πλήθος των κατηγοριών πρόβλεψης.

Η απόδοση ενός δέντρου μπορεί να αυξηθεί περαιτέρω με το κλάδεμα, το οποίο περιλαμβάνει την αφαίρεση των κλαδιών που χρησιμοποιούν χαρακτηριστικά χαμηλής σημασίας. Με αυτόν τον τρόπο, μειώνεται η πολυπλοκότητα του δέντρου και αυξάνεται η προβλεπτική του ικανότητα και η υπερπροσαρμογή περιορίζεται. Το κλάδεμα μπορεί να ξεκινήσει είτε από τη ρίζα είτε από τα φύλλα. Η απλούστερη μέθοδος κλαδέματος ξεκινά από τα φύλλα και αφαιρεί κάθε κόμβο με την πιο δημοφιλή κατηγορία σε αυτό το φύλλο. Το κλάδεμα αυτό διατηρείται μόνο εάν δεν επιδεινώνει την ακρίβεια του συνολικού μοντέλου.

Τα Δέντρα Αποφάσεων από μόνα τους έχουν κάποια μειονεκτήματα, όπως ότι καταλήγουν να είναι υπερβολικά πολύπλοκα ευνοώντας έτσι τα φαινόμενα υπερπροσαρμογής, ή μπορεί να είναι ασταθή επειδή μικρές παραλλαγές στα δεδομένα μπορεί να έχουν ως αποτέλεσμα τη δημιουργία ενός εντελώς διαφορετικού δέντρου απόφασης. Έχουν δηλαδή υψηλή διακύμανση η οποία μπορεί να μειωθεί με μεθόδους όπως το bagging.

Μία μέθοδος χαμηλής διακύμανσης θα αποφέρει παρόμοια αποτελέσματα εάν εφαρμοστεί επανειλημμένα σε διαφορετικά σύνολα δεδομένων. Στο bagging ένας φυσικός τρόπος για να μειωθεί η διακύμανση και να αυξηθεί η ακρίβεια είναι να ληφθούν πολλά διαφορετικά σύνολα εκπαίδευσης από τον πληθυσμό, να δημιουργηθεί και να εκπαιδευθεί ένα ξεχωρι-

στό μοντέλο πρόβλεψης χρησιμοποιώντας το συγκεκριμένο σύνολο δεδομένων εκπαίδευσης και τελικά να ληφθεί η πλειοψηφία των προβλέψεων των διαφορετικών μοντέλων για την δημιουργία της τελικής πρόβλεψης.

Έστω ένα σύνολο δεδομένων με  $n$  παρατηρήσεις. Δημιουργούνται  $B$  διαφορετικά σύνολα δεδομένων με δειγματοληψία bootstrap. Στη συνέχεια εκπαιδεύονται τα μοντέλα πρόβλεψης με τα  $B$  διαφορετικά σύνολα δεδομένων. Κατά τη διαδικασία της δημιουργίας προβλέψεων σε νέα δεδομένα (inference) καταγράφεται η κατηγορία που προβλέπει καθένα από τα  $B$  δέντρα και κρατείται η πρόβλεψη που εμφανίζεται στα περισσότερα από τα  $B$  δέντρα. Αυτή η μέθοδος ονομάζεται Bagged Trees.

Ο αλγόριθμος του Τυχαίου Δάσους (Random Forest) λειτουργεί ακριβώς όπως τα Bagged Trees προσφέρει όμως μια σημαντική βελτίωση που μειώνει τη συσχέτιση μεταξύ των διαφορετικών δέντρων. Κατά τη δημιουργία των επιμέρους δέντρων απόφασης, αφού πραγματοποιηθεί δειγματοληψία bootstrap στο σύνολο δεδομένων για την επιλογή των παρατηρήσεων, κάθε φορά που εξετάζεται μια διαίρεση σε ένα δέντρο, μόνο ένα τυχαίο δείγμα  $m$  χαρακτηριστικών επιλέγεται ως υποψήφιο για το διαχωρισμό του φύλλου από το πλήρες σύνολο των  $p$  χαρακτηριστικών. Η διαίρεση κάθε φορά τελικά γίνεται με βάση ένα μόνο χαρακτηριστικό και ένα νέο δείγμα  $m$  χαρακτηριστικών λαμβάνεται σε κάθε νέο διαχωρισμό. Πρακτικά για τιμή του  $m$  συνήθως επιλέγεται  $m = \sqrt{p}$  ή  $m = p/3$  χαρακτηριστικά από τα συνολικά  $p$ .

Με την παραπάνω διαδικασία εισάγεται τυχειότητα η οποία κάνει τα μεμονωμένα δέντρα απόφασης πιο μοναδικά και μειώνει τη συσχέτιση μεταξύ των δέντρων, γεγονός που βελτιώνει τη συνολική απόδοση του αλγορίθμου καθώς μειώνει τη διακύμανση των επιμέρους δέντρων. Κάτι τέτοιο είναι σημαντικό ιδίως όταν εξετάζεται ένα μεγάλο πλήθος χαρακτηριστικών με υψηλή συσχέτιση μεταξύ τους.

Ο αλγόριθμος του Τυχαίου Δάσους περιλαμβάνει ένα πλήθος υπερπαραμέτρων που μπορούν να επιλεχθούν κατά την εκπαίδευση του μοντέλου:

- **n\_estimators:** Το πλήθος των Δέντρων Απόφασης που δημιουργεί ο αλγόριθμος. Γενικά, μεγαλύτερος αριθμός δέντρων αυξάνει την απόδοση και κάνει τις προβλέψεις πιο σταθερές, αλλά επιβραδύνει επίσης τους υπολογισμούς.
- **max\_features:** Ο μέγιστος αριθμός χαρακτηριστικών που λαμβάνονται υπόψη στο διαχωρισμό ενός κόμβου
- **mini\_sample\_leaf:** Ο ελάχιστος αριθμός φύλλων που απαιτούνται για τη διαίρεση ενός εσωτερικού κόμβου.

Ο αλγόριθμος του Τυχαίου Δάσους έχει ένα πλήθος πλεονεκτημάτων που τον καθιστούν μοναδικό. Είναι ανεκτικός σε χαρακτηριστικά που έχουν μεταξύ τους υψηλή συσχέτιση, πετυχαίνει γενικά αρκετά καλά αποτελέσματα και γενικά είναι ιδιαίτερα ανθεκτικός σε φαινόμενα υπερπροσαρμογής ιδίως όταν επιλέγεται να χρησιμοποιηθεί ένα μεγάλο πλήθος διαφορετικών δέντρων.

## 2.6 Μετρικές αξιολόγησης ταξινόμησης

Η αξιολόγηση ενός αλγορίθμου ταξινόμησης γίνεται με τη βοήθεια των μετρικών που περιγράφονται στη συνέχεια. Οι μετρικές αυτές είναι πολύ σημαντικές και στη σύγκριση μεταξύ των διαφορετικών μοντέλων.

Για τη συγκεντρωτική εμφάνιση των αποτελεσμάτων των προβλέψεων ενός αλγορίθμου δυαδικής ταξινόμησης χρησιμοποιείται ο πίνακας σύγχυσης (confusion matrix) ο οποίος περιλαμβάνει το πλήθος των προβλέψεων σε σχέση με την αντικειμενική αλήθεια. Παράδειγμα ενός τέτοιου πίνακα φαίνεται στον Πίνακα 2.1.

		Προβλέψεις	
		ΟΧΙ	ΝΑΙ
Αντικειμενική αλήθεια	ΟΧΙ	ΑΛΗΘΩΣ ΑΡΝΗ- ΤΙΚΕΣ	ΨΕΥΔΩΣ ΘΕΤΙ- ΚΕΣ
	ΝΑΙ	ΨΕΥΔΩΣ ΑΡΝΗ- ΤΙΚΕΣ	ΑΛΗΘΩΣ ΘΕΤΙ- ΚΕΣ

Πίνακας 2.1: Πίνακας σύγχυσης μοντέλου δυαδικής ταξινόμησης.

Στον πίνακα αυτό διακρίνουμε τις ακόλουθες κατηγορίες προβλέψεων:

1. **Αληθώς Αρνητικές ή True Negatives:** Το μοντέλο έχει κάνει σωστή αρνητική πρόβλεψη.
2. **Αληθώς Θετικές ή True Positives:** Το μοντέλο έχει κάνει σωστή θετική πρόβλεψη.
3. **Ψευδώς Αρνητικές ή False Negatives:** Το μοντέλο έχει κάνει λανθασμένη αρνητική πρόβλεψη.
4. **Ψευδώς Θετικές ή False Positives:** Το μοντέλο έχει κάνει λανθασμένη θετική πρόβλεψη.

Στο πρόβλημα που εξετάζεται στη διπλωματική οι ψευδώς αρνητικές προβλέψεις (False negatives ή Type II Error) είναι αρκετά σημαντικό να διατηρούνται σε χαμηλά επίπεδα επειδή στην περίπτωση αυτή το μοντέλο έχει προβλέψει ότι δεν υπάρχει σκολίωση ενώ στην πραγματικότητα ο ασθενής έχει σκολίωση. Κάτι τέτοιο μπορεί να οδηγήσει στη μη έγκαιρη διάγνωση της σκολίωσης να επιδεινώσει την εξέλιξη της νόσου. Αντιθέτως οι ψευδώς θετικές προβλέψεις (False positives ή Type I Error) δεν έχουν το ίδιο αρνητικό αντίκτυπο καθώς απλά μπορεί να επιβαρύνουν τον εξεταζόμενο με επιπλέον αχρείαστες εξετάσεις.

Η Ακρίβεια (**Accuracy**) είναι μία μετρική απόδοσης ενός μοντέλου δυαδικής ταξινόμησης και αντιπροσωπεύει τον αριθμό των σωστά ταξινομημένων παρατηρήσεων επί του συνολικού αριθμού των παρατηρήσεων και δίνεται από τον παρακάτω τύπο:



$$Accuracy = \frac{TN + TP}{TN + FP + TP + FN} \quad (2.20)$$

Η μετρική αυτή λαμβάνει τιμές από το 0 ως το 1 και είναι χρήσιμη όταν και οι δύο τύποι σφάλματος (τύπου I και II) είναι το ίδιο σημαντικοί για το μοντέλο. Κάτι τέτοιο στο συγκεκριμένο πρόβλημα δεν ισχύει καθώς οι Ψευδώς Αρνητικές προβλέψεις έχουν μεγαλύτερο αρνητικό αντίκτυπο στο μοντέλο από τις Ψευδώς Θετικές. Για τον λόγο αυτό γίνεται χρήση δύο επιπλέον μετρικών που ονομάζονται Precision και Recall και δίνονται από τους ακόλουθους τύπους:

$$Precision = \frac{TP}{TP + FP} \quad (2.21)$$

$$Recall = \frac{TP}{TP + FN} \quad (2.22)$$

Η μετρική **Precision** μετράει πόσες από τις θετικές προβλέψεις που έγιναν είναι σωστές και δίνει μία εκτίμηση για το πόσο ακριβές είναι ένα μοντέλο στις θετικές προβλέψεις δηλαδή στους ασθενείς με σκολίωση. Η μετρική Precision λαμβάνει την τιμή 1 όταν τα ψευδώς θετικά είναι 0 και αποτελεί μία καλή μετρική για την επιλογή ενός μοντέλου, όταν το κόστος των Ψευδώς Θετικών είναι υψηλό, κάτι που δε συμβαίνει στο πρόβλημα που εξετάζεται.

Αντίστοιχα η μετρική **Recall** υπολογίζει πόσες από τις πραγματικά θετικές παρατηρήσεις προβλέπονται από το μοντέλο μας ως θετικές (Αληθώς Θετικές). Λαμβάνει την τιμή 1 όταν οι Ψευδώς Αρνητικές προβλέψεις είναι 0 και βοηθάει στην επιλογή του καλύτερου μοντέλου όταν υπάρχει υψηλό κόστος που σχετίζεται με τις Ψευδώς Αρνητικές προβλέψεις όπως συμβαίνει και στο πρόβλημα που εξετάζεται στην παρούσα διπλωματική εργασία.

Η μετρική **F1-Score** λαμβάνει υπόψη της τις μετρικές Precision και Recall και ορίζεται ως εξής:

$$F1 = 2 \frac{Precision * Recall}{Precision + Recall} \quad (2.23)$$

Η μετρική F1-Score ισούται με 1 μόνο όταν οι μετρικές Precision και Recall είναι και οι δύο 1, και γενικά έχει υψηλή τιμή μόνο όταν και οι δύο μετρικές Precision και Recall είναι υψηλές. Η μετρική F1-Score γίνεται υψηλή μόνο όταν οι μετρικές Precision και Recall είναι υψηλές. Σε σχέση με την μετρική Accuracy προσφέρει μεγαλύτερη ευαισθησία σε χαμηλές τιμές των Precision και Recall επομένως και στις Ψευδώς Αρνητικές και Ψευδώς Θετικές προβλέψεις ιδίως στις περιπτώσεις που μπορεί τα δεδομένα να μην είναι ισορροπημένα. Επομένως στην περίπτωση αυτή των μη ισορροπημένων δεδομένων εάν υπάρχει υψηλό ποσοστό Ψευδώς Αρνητικών ή Ψευδώς Θετικών προβλέψεων η μετρική Accuracy δεν μπορεί να το εκφράσει. Η μετρική F1-Score κρίνεται χρήσιμη σαν μετρική για το πρόβλημα της παρούσας διπλωματικής, καθώς οι ψευδώς αρνητικές προβλέψεις έχουν σημαντικές συνέπειες στην υγεία του ασθενή. Επειδή οι παρατηρήσεις του συνόλου δεδομένων είναι σχετικά ισορροπημένες στις δύο κατηγορίες πρόβλεψης αντίστοιχη ενημέρωση για την ακρίβεια των μοντέλων μπορεί να παρέχει και η μετρική Accuracy.

Η μετρική F1-Score ισούται με 1 μόνο όταν οι μετρικές Precision και Recall είναι και οι δύο 1, και γενικά έχει υψηλή τιμή μόνο όταν και οι δύο μετρικές Precision και Recall είναι υψηλές. Η βαθμολογία F1 γίνεται υψηλή μόνο όταν η ακρίβεια και η ανάκληση είναι

υψηλή. Σε σχέση με την μετρική Accuracy προσφέρει μεγαλύτερη ευαισθησία σε χαμηλές τιμές των Precision και Recall επομένως και στα Ψευδώς αρνητικά και Ψευδώς θετικά ιδίως στις περιπτώσεις που μπορεί τα δεδομένα να μην είναι ισορροπημένα, επομένως ενώ έχουμε υψηλό ποσοστό Ψευδώς αρνητικών ή Ψευδώς θετικών η μετρική Accuracy να μην μπορεί να εκφράσει. Επομένως κρίνεται χρήσιμη σαν μετρική για το πρόβλημα της παρούσας διπλωματικής, καθώς οι ψευδώς αρνητικές προβλέψεις έχουν σημαντικές συνέπειες στην υγεία του ασθενή και την εξέλιξη της νόσου του.

## 2.7 Εξαγωγή χαρακτηριστικών

Στη μηχανική μάθηση, την αναγνώριση προτύπων και την επεξεργασία εικόνας, η εξαγωγή χαρακτηριστικών ξεκινά από ένα αρχικό σύνολο μετρούμενων δεδομένων και δημιουργεί παράγωγες τιμές (χαρακτηριστικά) που προορίζονται να παρέχουν καλή ενημέρωση και να μην επαναλαμβάνονται, διευκολύνοντας τα επόμενα βήματα της μάθησης και γενίκευσης και σε ορισμένες περιπτώσεις οδηγεί σε καλύτερες ανθρώπινες ερμηνείες.

Όταν τα δεδομένα εισόδου σε έναν αλγόριθμο είναι πολύ μεγάλα για απευθείας επεξεργασία και υπάρχει υποψία ότι είναι περιττά, τότε μπορεί να μετατραπούν σε μειωμένο σύνολο των χαρακτηριστικών που ονομάζεται διάνυσμα χαρακτηριστικών. Τα επιλεγμένα χαρακτηριστικά αναμένεται να περιέχουν τις σχετικές πληροφορίες από τα δεδομένα εισόδου, έτσι ώστε η επιθυμητή εργασία να μπορεί να εκτελεστεί χρησιμοποιώντας αυτήν τη μειωμένη αναπαράσταση αντί για τα πλήρη αρχικά δεδομένα.

### Σχετικές εργασίες και συναφής βιβλιογραφία

---

**Η** εξέλιξη των μεθόδων Μηχανικής Μάθησης έχει δημιουργήσει νέες μεθόδους και εργαλεία διάγνωσης και παρακολούθησης της ιδιοπαθούς σκολίωσης. Στην ενότητα αυτή θα μελετήσουμε τις δύο πιο σημαντικές κατηγορίες ηλεκτρονικών εργαλείων για τη μέτρηση και την αξιολόγηση της σκολίωσης και της γωνίας Cobb.

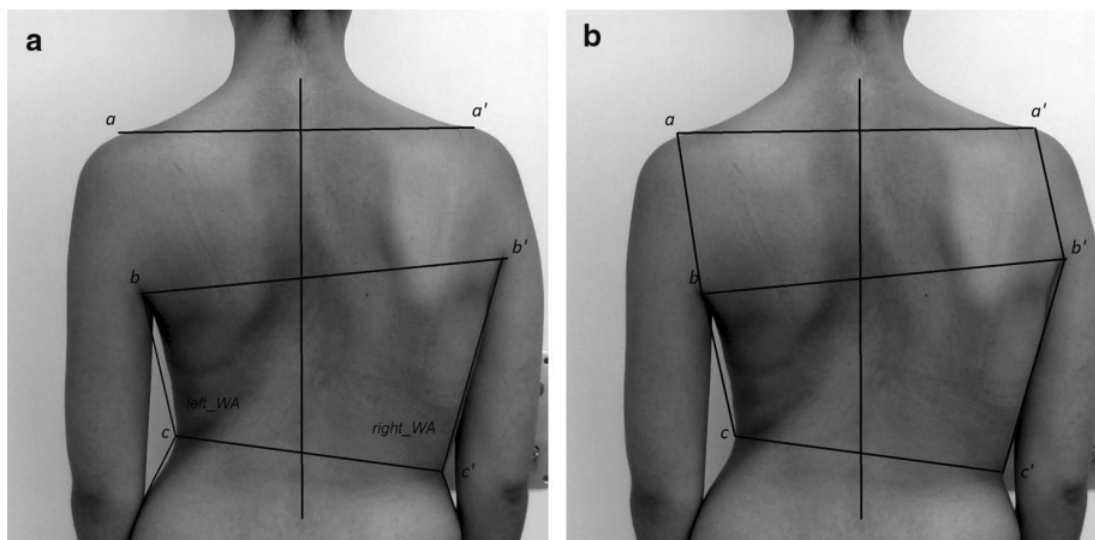
Η πρώτη μέθοδος αφορά τη χρήση ηλεκτρονικού σκολιόμετρου. Σύμφωνα με τη δημοσίευση [12] ερευνητές δημιούργησαν ένα ηλεκτρονικό σκολιόμετρο το οποίο χρησιμοποιεί το επιταχυνσιόμετρο του κινητού τηλεφώνου για να καταγράψει τη καμπυλότητα της σπονδυλικής στήλης. Ο εξεταζόμενος στην περίπτωση βρίσκεται σε θέση επίκυψης και ο εξεταστής εφαρμόζει το κινητό στην πλάτη του εξεταζομένου κατά μήκος της σπονδυλικής του στήλης. Το επιταχυνσιόμετρο συλλέγει δεδομένα τα οποία ανασυντίθενται σε μία βάση δεδομένων και κατόπιν κατάλληλης επεξεργασίας υπολογίζεται η γωνία Cobb που εκφράζει τη βαρύτητα της σκολίωσης.

Η μέθοδος του ηλεκτρονικού σκολιόμετρου από μόνη της για την ανίχνευση ιδιοπαθούς σκολίωσης μπορεί να μην αποτελεί αξιόπιστη τεχνική καθώς από μελέτες όπως η [13] προέκυψε ότι τα αποτελέσματα που δίνει για πραγματική Cobb Angle μικρότερη από  $10^\circ$ , δεν μπορούν να θεωρηθούν στατιστικά σημαντικά ( $p\text{-value}=0.035$ ). Ενδεχομένως όμως σε ένα μοντέλο πολλαπλής παλινδρόμησης με επιπλέον μεταβλητές πρόβλεψης να ληφθούν καλύτερα αποτελέσματα.

Η δεύτερη διαγνωστική μέθοδος χρησιμοποιεί φωτογραφίες δύο διαστάσεων της πλάτης των εξεταζόμενων που λαμβάνονται από μία φωτογραφική μηχανή ή ένα κινητό τηλέφωνο. Στις φωτογραφίες αυτές συνήθως αφού πραγματοποιηθεί οπτικός εντοπισμός συγκεκριμένων σημείων του σώματος δημιουργούνται μετρήσεις που χρησιμοποιούνται ως είσοδος σε μοντέλο μηχανικής μάθησης για τη δημιουργία πρόβλεψης γωνίας Cobb.

Μία κρίσιμη παράμετρος για τη μέθοδο αυτή είναι η ευαισθησία της και κατά πόσο μπορεί να συσχετιστεί με την πρόληψη και την παρακολούθηση της ιδιοπαθούς σκολίωσης σε πρώιμο στάδιο ή εάν είναι κατάλληλη μόνο για την ανίχνευση βαριάς μορφής σκολίωσης που χρήζει χειρουργικής επέμβασης.

Στην δημοσίευση [2] έχει γίνει ανάπτυξη μοντέλου το οποίο χρησιμοποιήθηκε περισσότερο για ανίχνευση ιδιοπαθούς σκολίωσης που χρήζει χειρουργικής επέμβασης. Στη μέθοδο που χρησιμοποιήθηκε οι ασθενείς κλήθηκαν να υιοθετήσουν μία χαλαρή όρθια θέση κατά τη λήψη των φωτογραφιών και η λήψη της φωτογραφίας της πλάτης του ασθενούς έγινε από απόσταση 1,3m.



Εικόνα 3.1: Εικόνα πλάτης ασθενή με τους οδηγούς των υπολογιζόμενων χαρακτηριστικών που λήφθηκε από τη δημοσίευση [2]

Στη παραπάνω δημοσίευση υπολογίστηκαν τα ακόλουθα μεγέθη:


1. Shoulder height angle (SHA): η γωνία που σχηματίζεται μεταξύ της γραμμής που ενώνει τους δύο ώμους και τον οριζόντιο άξονα.
2. Axilla height angle (AHA): η γωνία που σχηματίζεται μεταξύ της γραμμής που ενώνει τις δύο μασχάλες και τον οριζόντιο άξονα.
3. Waist height angle (WHA): η γωνία μεταξύ της γραμμής που ενώνει τις δύο πτυχές της μέσης και τον οριζόντιο άξονα.

Η μελέτη κατέληξε ότι η χρήση εικόνων δύο διαστάσεων ενδεχομένως δεν διαθέτει την απαραίτητη ακρίβεια και δεν αποτελεί αποτελεσματική μέθοδο για την παρακολούθηση της εξέλιξης της ιδιοπαθούς σκολίωσης, παρά μόνο για τη γρήγορη ανίχνευση και μία πρώτη αξιολόγηση της.

Στη δημοσίευση [3] έγινε προσπάθεια σύνδεσης της γωνίας Cobb με αριθμητικά μεγέθη που δημιουργήθηκαν έπειτα από την επεξεργασία εικόνων της πλάτης των ασθενών.

Τα μεγέθη που υπολογίστηκαν στη δημοσίευση [3] και φαίνονται στην Εικόνα 3.2 είναι τα ακόλουθα:

1. Waist Height Angle (WHA): η γωνία μεταξύ μιας γραμμής που ενώνει τη δεξιά κοιλότητα της μέσης με την αριστερή κοιλότητα των πλευρών και της οριζόντιας γραμμής.
2. Right and left waist angle (RWA/LWA): η γωνία που σχηματίζεται από τη γραμμή του πλευρικού τμήματος του θώρακα με την εφαπτομένη στην κοιλότητα της μέσης και για τις δύο πλευρές.
3. Waistline distance ratio (WLDR): Ο λόγος της απόστασης σε mm της κάθετης γραμμής που διέρχεται από τον αυχένα με τις κορυφές της κοιλότητας της μέσης.



Εικόνα 3.2: Παράδειγμα φωτογραφιών που ελήφθησαν στη δημοσίευση [3] με τα υπολογιζόμενα μεγέθη

Στην τελευταία μελέτη προκύπτει στατιστικά σημαντική συσχέτιση μεταξύ της πραγματικής γωνίας Cobb, και της μετρικής WHA. Φάνηκε όμως κάποιοι παράγοντες μπορούν να μειώσουν την αξιοπιστία των αποτελεσμάτων όπως η κλίση της συσκευής λήψης της φωτογραφίας κατά τη λήψη της φωτογραφίας, ο δείκτης μάζας σώματος BMI του ασθενή καθώς σε παχύσαρκα άτομα μπορεί να είναι δυσκολότερος ο αυτόματος εντοπισμός των σημείων κλειδιών και, τέλος, η θέση του ασθενή που μπορεί να μην είναι απόλυτα χαλαρή και ισοροπημένη.



**Μέρος **

**Πρακτικό Μέρος**

---





## Κεφάλαιο 4

### Περιγραφή δεδομένων και εργαλείων

---

Στο κεφάλαιο αυτό παρουσιάζεται το σύνολο δεδομένων που χρησιμοποιήθηκε στη παρούσα διπλωματική για την εκπαίδευση και την αξιολόγηση των μοντέλων Μηχανικής Μάθησης για τον εντοπισμό της σκολίωσης σε εικόνες πλάτης ατόμων. Επίσης παρουσιάζονται τα εργαλεία που χρησιμοποιήθηκαν για την εξαγωγή των χαρακτηριστικών από τις εικόνες και για την εκπαίδευση των μοντέλων.

#### 4.1 Περιγραφή συνόλου δεδομένων

Καθώς το πρόβλημα που πραγματεύεται η παρούσα εργασία είναι ένα πρόβλημα δυαδικής ταξινόμησης για την ύπαρξη ή όχι σκολίωσης έπρεπε να συγκεντρωθεί ένα ικανός αριθμός εικόνων πλάτης ατόμων με ή χωρίς σκολίωση και να δημιουργηθεί ένα σύνολο δεδομένων για την εκπαίδευση και την επαλήθευση των μοντέλων Μηχανικής Μάθησης.

Κατόπιν αναζήτησης που πραγματοποιήθηκε σε σύνολα δεδομένων ανοικτής πρόσβασης για τη σκολίωση φάνηκε ότι δεν υπήρχε κάποιο κατάλληλο σύνολο δεδομένων. Τα περισσότερα σύνολα δεδομένων για σκολίωση όπως για παράδειγμα το [14] αφορούσαν εικόνες ακτίνων X κάτι που δε ταιριάζει στην δική μας περίπτωση.

Έτσι πραγματοποιήθηκε η δημιουργία του συνόλου δεδομένων. Το σύνολο δεδομένων που δημιουργήθηκε αποτελείται συνολικά από 95 εικόνες πλάτης ατόμων και στις 47 εικόνες απεικονίζεται η πλάτη ασθενών με σκολίωση και στις 48 εικόνες απεικονίζεται η πλάτη υγιών ατόμων, όπως φαίνεται στον πίνακα 4.1. Η δημιουργία του συνόλου δεδομένων έγινε με τεχνικές web scraping και με αναζήτηση στον παγκόσμιο ιστό. Οι εικόνες που εντοπίστηκαν αποθηκεύτηκαν σε τοπικό αποθηκευτικό χώρο στον πηγαίο μορφότυπο του αρχείου.

Περιγραφή	
Πλήθος εικόνων με σκολίωση	47
Πλήθος εικόνων χωρίς σκολίωση	48
Σύνολο εικόνων	95

Πίνακας 4.1: Πλήθος παρατηρήσεων συνόλου δεδομένων με κατανομή στις επιμέρους κατηγορίες.

Τα βασικά κριτήρια που τέθηκαν για τη συλλογή των εικόνων και τη δόμηση του συνόλου δεδομένων ήταν τα εξής:

1. η κάθε εικόνα να απεικονίζει την πλάτη ενός ατόμου σε όρθια θέση από το κεφάλι μέχρι και τα πόδια,
2. ο άνθρωπος να μη φοράει μπλούζα,
3. η φωτογραφία να έχει ληφθεί από σχετικά κοντινή απόσταση,
4. ο άνθρωπος που απεικονίζεται να μην έχει μακριά μαλλιά που να καλύπτουν μεγάλο μέρος της πλάτης, μπορεί όμως να έχει μετρίου μήκους μαλλιά,
5. ο φωτισμός και η ανάλυση της φωτογραφίας να είναι σχετικά ικανοποιητικά, χωρίς όμως να έχουν αποκλειστεί εικόνες χαμηλότερης ανάλυσης, ή πιο φτωχού φωτισμού.

Οι εικόνες ασθενών με σκολίωση ελήφθησαν από δημοσιεύσεις ανοικτής πρόσβασης όπως η [4].



Εικόνα 4.1: Παράδειγμα εικόνας πλάτης ασθενών με σκολίωση που λήφθηκε από τη δημοσίευση [4]

Για τη δόμηση του συνόλου δεδομένων χρησιμοποιήθηκαν πολλές διαφορετικές πηγές λήψης των εικόνων έτσι ώστε να εξασφαλιστεί περισσότερο η ανεξαρτησία μεταξύ των παρατηρήσεων αλλά και η ανοχή του σχεδιαζόμενου συστήματος σε συνθήκες διαφορετικού φωτισμού, τρόπου λήψης, ανάλυσης της εικόνας κ.λπ. Οι εικόνες ήταν σχετικά ισορροπημένες σε πλήθος ανάμεσα σε διαφορετικά φύλα όπως άνδρες και γυναίκες και ανάμεσα σε

διαφορετικές ηλικιακές κατηγορίες όπως ενήλικες ή παιδιά. Με αυτόν τον τρόπο εξασφαλίσαμε ότι η εκπαίδευση του συστήματος μηχανικής μάθησης θα βασίζεται σε εικόνες με υψηλή ετερογένεια έτσι ώστε να μπορεί να πραγματοποιήσει ορθές προβλέψεις σε μεγαλύτερο εύρος περιπτώσεων και να μην υπερπροσαρμοστεί σε συγκεκριμένου τύπου ή ηλικιακού εύρους εικόνες.

Αφού συγκεντρώθηκαν οι εικόνες πραγματοποιήθηκε μία αρχική προεπεξεργασία τους και πραγματοποιήθηκαν με πρόγραμμα επεξεργασίας εικόνων οι ακόλουθες μετατροπές:

1. έγινε αποκοπή των εικόνων για την αφαίρεση μη χρήσιμων αντικειμένων όπως QR-Codes, συμβολοσειρών, πλαισίων κ.λπ. και για να απομονωθεί μόνο το χρήσιμο μέρος της εικόνας
2. ανεξαρτήτως του πηγαίου μορφότυπου αρχείου μετατράπηκαν όλες οι εικόνες σε μορφότυπο αρχείου PNG έτσι ώστε να είναι δυνατή η μετέπειτα μαζική επεξεργασία τους από τον αλγόριθμο εξαγωγής χαρακτηριστικών.

## 4.2 Εργαλεία

Για την εξαγωγή των χαρακτηριστικών και την εκπαίδευση των μοντέλων Μηχανικής Μάθησης χρησιμοποιήθηκε η γλώσσα προγραμματισμού Python. Η Python είναι μία γλώσσα προγραμματισμού υψηλού επιπέδου και χαρακτηρίζεται από απλότητα και συνέπεια, παρέχει ανεξαρτησία εκτέλεσης από την εκάστοτε υπολογιστική πλατφόρμα και διαθέτει μεγάλη κοινότητα υποστήριξης. Χρησιμοποιείται ευρέως σε τομείς όπως η Επιστήμη Δεδομένων και η Μηχανική Μάθηση και περιλαμβάνει αρκετές βιβλιοθήκες που παρέχουν λύσεις σε κοινά προβλήματα της Μηχανικής Μάθησης. Ενσωματώνει αρκετές βιβλιοθήκες γενικής χρήσης, όπως για παράδειγμα η βιβλιοθήκη επεξεργασίας εικόνων OpenCV που χρησιμοποιήθηκε για την εξαγωγή χαρακτηριστικών στην παρούσα διπλωματική.

Πιο αναλυτικά, για την ανάπτυξη των μοντέλων της διπλωματικής χρησιμοποιήθηκαν οι ακόλουθες βιβλιοθήκες:

### 4.2.1 Pandas

Το Pandas είναι μία βιβλιοθήκη της Python που παρέχει γρήγορες, ευέλικτες δομές δεδομένων που έχουν σχεδιαστεί για να κάνουν την εργασία με σχεσιακά δεδομένα εύκολη και διαισθητική. Χρησιμοποιήθηκε για την προεπεξεργασία και διαχείριση των αριθμητικών δεδομένων που προέκυψαν κατόπιν της εξαγωγής χαρακτηριστικών από τις εικόνες δύο διαστάσεων και για την εκπαίδευση και την αξιολόγηση των μοντέλων Μηχανικής Μάθησης.

### 4.2.2 Numpy

Το NumPy είναι μια βιβλιοθήκη της Python που αποτελείται από πολυδιάστατα αντικείμενα πινάκων και μια συλλογή από ρουτίνες για την επεξεργασία αυτών των πινάκων. Χρησιμοποιώντας το NumPy, μπορούν να εκτελεστούν μαθηματικές και λογικές πράξεις σε πίνακες. Στην εργασία χρησιμοποιήθηκε κυρίως για τη διαχείριση και το μετασχηματισμό των πινάκων που προέκυψαν από την ανάγνωση των εικόνων του συνόλου δεδομένων.

### 4.2.3 Math

Το `math` είναι ένα ενσωματωμένο πακέτο της Python που χρησιμοποιείται για μαθηματικές πράξεις. Παρέχει για παράδειγμα εύκολο υπολογισμό ημιτόνων, ολοκληρωμάτων, παραγώγων κ.λπ. Στην εργασία αυτή χρησιμοποιήθηκε για την πραγματοποίηση υπολογισμών κατά τη διαδικασία εξαγωγής αριθμητικών χαρακτηριστικών από τις εικόνες, όπως ο υπολογισμός γωνιών και εμβαδών πολυγώνων.

### 4.2.4 Matplotlib

Το Matplotlib είναι μια ολοκληρωμένη βιβλιοθήκη για τη δημιουργία απεικονίσεων στην Python. Οι απεικονίσεις μπορούν να είναι από απλά γραφήματα μέχρι εικόνες, και παρέχει δυνατότητες προσαρμογής του οπτικού στυλ και της διάταξης τους. Χρησιμοποιήθηκε για την οπτικοποίηση των εικόνων πριν και μετά την εξαγωγή των χαρακτηριστικών και για την οπτικοποίηση γραφημάτων κατά την ανάλυση των δεδομένων.

### 4.2.5 Seaborn

Το Seaborn είναι μια βιβλιοθήκη οπτικοποίησης δεδομένων για την Python που βασίζεται στο Matplotlib. Παρέχει μια διεπαφή υψηλότερου επιπέδου σε σχέση με το Matplotlib για τη σχεδίαση ελκυστικών και ενημερωτικών στατιστικών γραφικών με γρήγορο τρόπο. Χρησιμοποιήθηκε για την οπτικοποίηση γραφημάτων κατά την ανάλυση των δεδομένων.

### 4.2.6 scikit-learn

Το scikit-learn είναι μια βιβλιοθήκη Μηχανικής Μάθησης για τη γλώσσα προγραμματισμού Python. Διαθέτει διάφορους αλγόριθμους ταξινόμησης, παλινδρόμησης και ομαδοποίησης, όπως για παράδειγμα τους Support Vector Machines, Random Forest, Gradient Boosting, k-means and DBSCAN. Παρέχει δυνατότητες εκπαίδευσης αρκετών μοντέλων μηχανικής μάθησης και υπολογισμών μετρικών που αφορούν την εκπαίδευση αυτών των μοντέλων. Περιλαμβάνει επίσης βοηθητικά εργαλεία για χρήσιμες εργασίες όπως για παράδειγμα ο διαχωρισμός του συνόλου δεδομένων σε σύνολο δεδομένων εκπαίδευσης και ελέγχου. Στην εργασία χρησιμοποιήθηκε για την εκπαίδευση και την αξιολόγηση των Μοντέλων Μηχανικής Μάθησης αλλά και το διαχωρισμό του συνόλου δεδομένων σε σύνολο δεδομένων εκπαίδευσης και ελέγχου.

### 4.2.7 OpenCV

Το OpenCV είναι μια βιβλιοθήκη της Python που έχει σχεδιαστεί για την επίλυση προβλημάτων όρασης υπολογιστών. Χρησιμοποιήθηκε για την φόρτωση εικόνων σε πίνακες NumPy, για το μετασχηματισμό των εικόνων όπως η αλλαγή του μεγέθους τους και η αλλαγή των χρωματικών καναλιών τους.

### 4.2.8 Shapely

Το Shapely είναι ένα πακέτο της Python για το χειρισμό και ανάλυση επίπεδων γεωμετρικών αντικειμένων. Χρησιμοποιήθηκε για τον υπολογισμό του εμβαδού πολυγώνων που προέκυψαν κατόπιν της εξαγωγής χαρακτηριστικών από τις εικόνες του συνόλου δεδομένων.

### 4.2.9 Mediapipe

Το MediaPipe είναι ένα πακέτο της Google για τη επεξεργασία δεδομένων εικόνων, βίντεο και ήχου. Το πακέτο λειτουργεί σε περιβάλλον Desktop/Server, Android, iOS και ενσωματωμένες συσκευές όπως το Raspberry Pi ενώ διαθέτει και δυνατότητα κλήσης του μέσω της γλώσσας προγραμματισμού Python. Παρέχει προεκπαιδευμένα μοντέλα που βασίζονται στη βιβλιοθήκη Tensorflow και TFLite για τον εντοπισμό αντικειμένων και την εκτίμηση της στάσης του σώματος όπως για παράδειγμα την εύρεση σε μία εικόνα της θέσης του προσώπου ενός ατόμου, των σημείων του σώματός του όπως οι ώμοι, οι γοφοί, τα δάκτυλα κ.λπ. Χρησιμοποιήθηκε κατά την εξαγωγή των αριθμητικών χαρακτηριστικών από τις εικόνες για τον υπολογισμό των συντεταγμένων των ώμων και των γοφών στις εικόνες της πλάτης των ατόμων που περιλαμβάνονται στο σύνολο δεδομένων.



## Κεφάλαιο 5

### Επιλογή και εξαγωγή χαρακτηριστικών

---

**Η** εξαγωγή χαρακτηριστικών από εικόνες είναι ένα βασικό συστατικό της επιστήμης της όρασης υπολογιστών. Σύμφωνα με την δημοσίευση [15] τα μοντέλα Μηχανικής Μάθησης λειτουργούν γύρω από την ιδέα της εξαγωγής χρήσιμων χαρακτηριστικών που ορίζονται σαφώς από τα αντικείμενα σε μία εικόνα. Τα χαρακτηριστικά που εξάγονται είναι τα συνήθως αριθμητικά δεδομένα εισόδου που τροφοδοτούνται στο μοντέλο της Μηχανικής Μάθησης για να εκπαιδευθεί ένας αλγόριθμος και αργότερα εξαχθεί μια πρόβλεψη.

Κατά τη διαδικασία αυτή μετατρέπονται με διάφορες τεχνικές της όρασης υπολογιστών τα ακατέργαστα δεδομένα μίας εικόνας σε ένα διάνυσμα χαρακτηριστικών. Συνήθως δεν υπάρχει ένα μόνο χαρακτηριστικό που να μπορεί να ταξινομήσει με επιτυχία όλες τις παρατηρήσεις από μόνο του. Αυτός είναι ο λόγος για τον οποίο χρειαζόμαστε τις περισσότερες φορές πολλαπλά χαρακτηριστικά όπου κάθε χαρακτηριστικό ενσωματώνει έναν διαφορετικό τύπο πληροφοριών. Σε αντίθεση με τα προβλήματα Βαθιάς Μηχανικής Μάθησης όπου μία εικόνα μπορεί να τροφοδοτείται ολόκληρη σε ένα νευρωνικό δίκτυο, στα παραδοσιακά προβλήματα μηχανικής μάθησης, είναι σημαντικό η χειροκίνητη επιλογή χαρακτηριστικών να γίνει προσεκτικά και να βασιστεί στη γνώση του επιστημονικού τομέα των δεδομένων που εξετάζονται. Τα μοντέλα Μηχανικής Μάθησης διαθέτουν ανάλογη ακρίβεια με την ποιότητα και την ακρίβεια των χαρακτηριστικών που έχουν εξαχθεί από τις εικόνες.

#### 5.1 Επιλογή χαρακτηριστικών για την εκτίμηση της σκολίωσης

Στο πρόβλημα που εξετάζεται στην παρούσα διπλωματική χρειάζεται να γίνει εντοπισμός χαρακτηριστικών κατάλληλων για να πραγματοποιηθεί πρόβλεψη εάν κάποιο άτομο έχει σκολίωση ή όχι. Συνεπώς, τα χαρακτηριστικά που χρειάζεται να εξαχθούν αφορούν κυρίως την γεωμετρία και την συμμετρία της πλάτης ενός ανθρώπου. Για παράδειγμα μπορεί να γίνει εξαγωγή του περιγράμματος της πλάτης ενός ανθρώπου ως γεωμετρικό σχήμα έτσι ώστε στη συνέχεια με μαθηματικές πράξεις να εξεταστεί η συμμετρία αυτού του γεωμετρικού σχήματος δημιουργώντας αριθμητικά μεγέθη τα οποία θα τροφοδοτήσουν αλγόριθμους επιβλεπόμενης Μηχανικής Μάθησης για την δημιουργία προβλέψεων.

Η ανίχνευση των ακμών σε μία εικόνα είναι ένα πρόβλημα όρασης υπολογιστών το οποίο μπορεί να επιλυθεί είτε με κλασικές αριθμητικές μεθόδους όπως για παράδειγμα η διαφορίση για την εύρεση αλλαγών φωτισμού, είτε με μεθόδους Βαθιάς Μηχανικής Μάθησης. Σύμφωνα με τη δημοσίευση [16] στην εξαγωγή χαρακτηριστικών οι αλγόριθμοι Βαθιάς Μη-

χανικής Μάθησης παρουσιάζουν καλύτερη απόδοση σε σχέση με τις κλασικές μεθόδους ως προς την ακρίβεια και τον χρόνο ανάπτυξης. Έχουν όμως και κάποια μειονεκτήματα όπως για παράδειγμα οι υψηλές απαιτήσεις τους σε υπολογιστικούς πόρους και η αδυναμία εφαρμογής τους σε διαφορετικού τύπου δεδομένα από αυτά πάνω στα οποία έχουν εκπαιδευτεί. Λόγω του τελευταίου συμπεράσματος για την εξαγωγή χαρακτηριστικών πραγματοποιήθηκε αναζήτηση προεκπαιδευμένων δικτών Βαθιάς Μηχανικής Μάθησης με εξειδίκευση στην εκτίμηση της στάσης του σώματος.

Τα κριτήρια που τέθηκαν για την αναζήτηση ενός τέτοιου μοντέλου ήταν η εκπαίδευσή του να έχει βασιστεί σε μεγάλο όγκο δεδομένων έτσι ώστε να πετυχαίνει υψηλή ακρίβεια και να μπορεί εύκολα να γενικεύσει τις προβλέψεις του σε άγνωστες παρατηρήσεις. Άλλα δευτερεύοντα κριτήρια που τέθηκαν ήταν οι χαμηλές απαιτήσεις του σε υπολογιστικούς πόρους και η κοινότητα ανάπτυξης και υποστήριξης. Η βιβλιοθήκη που κάλυπτε τα κριτήρια αυτά ήταν η *Mediaripe* [17]. Είναι ανοικτού κώδικα με δυνατότητα δωρεάν χρήσης καθώς διατίθεται με άδεια Apache 2.0, έχει εκπαιδευτεί σε μεγάλο όγκο δεδομένων και έχει χαμηλές απαιτήσεις σε υπολογιστικούς πόρους, καθώς μπορεί να εκτελείται ακόμη και σε ενσωματωμένες συσκευές.

Η βιβλιοθήκη *Mediaripe* προσφέρει αρκετές δυνατότητες όπως η αναγνώριση του προσώπου ενός ατόμου, η αναγνώριση αντικειμένων κ.λπ., για τις ανάγκες όμως της διπλωματικής χρησιμοποιήθηκε το πακέτο της βιβλιοθήκης που επιτρέπει την εκτίμηση της στάσης του σώματος (*Posture estimation*).

Τροφοδοτώντας το μοντέλο *mediaripe* με μία εικόνα και στη συνέχεια καλώντας την συνάρτηση *Pose* ελήφθησαν οι συντεταγμένες των σημείων του σώματος που ενδιαφέρουν καθώς και οι μεταξύ τους συνδέσεις. Στη συνέχεια χρησιμοποιήθηκε η συνάρτηση *draw\_landmarks* για τη σχεδίαση των συντεταγμένων των σημείων του σώματος πάνω στην εικόνα και κατόπιν με κλήση της συνάρτησης *cv2.imshow* της βιβλιοθήκης *OpenCV* εμφανίστηκε η εικόνα μαζί με τις επισήμανσεις των σημείων του σώματος. Πράγματι στην Εικόνα 5.1 παρουσιάζεται μία φωτογραφία του συνόλου δεδομένων πριν και μετά την επισήμανση των συντεταγμένων.

Πραγματοποιήθηκε μαζική επισήμανση των συντεταγμένων των σημείων του σώματος σε όλες τις εικόνες του συνόλου δεδομένων και οι συντεταγμένες αυτές αποθηκεύτηκαν σε μία λίστα.


Αφού λήφθηκαν οι συντεταγμένες του πολυγώνου της πλάτης όλων των ανθρώπων πραγματοποιήθηκε υπολογισμός παράγωγων μεγεθών, καθώς οι συντεταγμένες αυτές καθαυτές δεν έχουν ουσιαστική αξία στην εκπαίδευση ενός μοντέλου Μηχανικής Μάθησης. Αρκετές μελέτες [2] [3] που περιλαμβάνουν την εξαγωγή χαρακτηριστικών από δισδιάστατες εικόνες για την αξιολόγηση της σκολίωσης προσπαθούν να εντοπίσουν αριθμητικά στοιχεία και δείκτες που αφορούν τη συμμετρία της πλάτης. Με βάση λοιπόν τη βιβλιογραφία και την εφαρμογή της στο πρόβλημα της διπλωματικής έγινε ο υπολογισμός των ακόλουθων μεγεθών όπως φαίνονται στην Εικόνα 5.2.

Έστω  $A$  το σημείο που αντιστοιχεί στον αριστερό ώμο,  $B$  το σημείο που αντιστοιχεί στο δεξί ώμο,  $\Gamma$  το σημείο που αντιστοιχεί στον δεξιό γοφό και  $\Delta$  το σημείο που αντιστοιχεί στον αριστερό γοφό. Έστω  $E$  το μέσο του ευθύγραμμου τμήματος  $AB$  και  $Z$  το μέσο του ευθύγραμμου τμήματος  $\Gamma\Delta$ . Έγινε ο υπολογισμός των ακόλουθων μεγεθών:



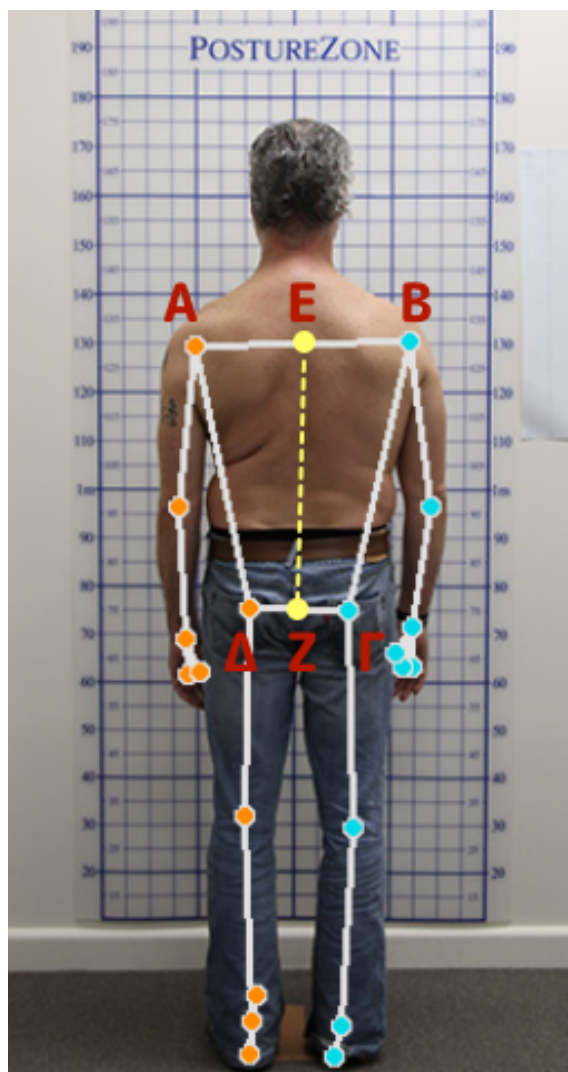


(α) Εικόνα συνόλου δεδομένων πριν την επισήμανση



(β) Εικόνα με επισήμανση συντεταγμένων σημείων του σώματος

Εικόνα 5.1: Δείγμα εικόνας του συνόλου δεδομένων πριν και μετά την επισήμανση των συντεταγμένων των σημείων του σώματος με τη βιβλιοθήκη mediapipe



Εικόνα 5.2: Εικόνα του συνόλου δεδομένων έπειτα από την επισήμανση των σημείων του σώματος από το μονέλο *mediaripre* και τον υπολογισμό των παράγωγων μεγεθών

1. **HS**: Η γωνία σε μοίρες που σχηματίζει το ευθύγραμμο τμήμα AB με τον οριζόντιο άξονα
2. **HH**: Η γωνία σε μοίρες που σχηματίζει το ευθύγραμμο τμήμα ΓΔ με τον οριζόντιο άξονα
3. **VL**: Η γωνία σε μοίρες που σχηματίζει το ευθύγραμμο τμήμα AΔ με τον οριζόντιο άξονα
4. **VR**: Η γωνία σε μοίρες που σχηματίζει το ευθύγραμμο τμήμα ΒΓ με τον οριζόντιο άξονα
5. **DVRVL**: Η απόλυτη τιμή διαφοράς των απολύτων τιμών των μεγεθών VR και VL
6. **VSPINE**: Η γωνία σε μοίρες που σχηματίζει το ευθύγραμμο τμήμα EZ με τον οριζόντιο άξονα.
7. **LPOL\_AREA**: Το εμβαδό του πολυγώνου AEZA.
8. **RPOL\_AREA**: Το εμβαδό του πολυγώνου EBGZ.
9. **AREA\_DIFF**: Η απόλυτη τιμή της διαφοράς του εμβαδού των πολυγώνων AEZA και EBGZ.

Μετά την επεξεργασία κάθε εικόνας και αφού προστέθηκε η ετικέτα της σκολίωσης (1 εάν η εικόνα αφορούσε ασθενή με σκολίωση ή 0 εάν η εικόνα αφορούσε άτομο χωρίς σκολίωση), δημιουργήθηκε ένα Pandas Dataframe με όλα τα παραπάνω αριθμητικά δεδομένα έτοιμο για να τροφοδοτήσει στο επόμενο στάδιο της εκπαίδευσης και της αξιολόγησης των μοντέλων Μηχανικής Μάθησης. Στους πίνακες 5.1 και 5.2 παρουσιάζεται δείγμα των δεδομένων του αριθμητικού συνόλου δεδομένων που προέκυψε κατόπιν της διαδικασίας εξαγωγής χαρακτηριστικών συνοδευόμενο από την ετικέτα scoliosis που δηλώνει την ύπαρξη ή όχι σκολίωσης.

HS	HH	VL	VR	DVRVL	VSPINE
-2.971	-1.863	75.197	83.380	8.183	85.903
-0.428	-2.397	80.817	78.692	2.124	88.949
0.573	-2.349	78.988	76.005	2.984	88.602
2.696	-2.668	79.818	77.522	2.296	89.135

Πίνακας 5.1: Το σύνολο δεδομένων κατόπιν της εξαγωγής των χαρακτηριστικών από τις εικόνες ασθενών με σκολίωση και υγιών ατόμων.

LPOL_AREA	RPOL_AREA	AREA_DIFF	scoliosis
2124.559	2133.794	9.235	1
4863.927	4826.342	37.585	1
18341.532	18075.147	266.386	0
11270.551	10985.835	284.717	0

Πίνακας 5.2: Το σύνολο δεδομένων κατόπιν της εξαγωγής των χαρακτηριστικών από τις εικόνες ασθενών με σκολίωση και υγιών ατόμων. (συνέχεια)



## Κεφάλαιο 6

# Εκπαίδευση και αξιολόγηση μοντέλων μηχανικής μάθησης

Το τελευταίο στάδιο της εργασίας περιλαμβάνει την εκπαίδευση και την αξιολόγηση τριών μοντέλων Μηχανικής Μάθησης: της Λογιστικής Παλινδρόμησης (Logistic Regression), των Μηχανών Διανυσμάτων Υποστήριξης (Support Vector machines) και του Τυχαίου Δάσους (Random Forest). Κάθε μοντέλο που προέκυψε αξιολογήθηκε ως προς την απόδοσή του και την ακρίβειά του στην επίλυση του προβλήματος της δυαδικής ταξινόμησης (Ύπαρξη σκολίωσης/Μη ύπαρξη σκολίωσης) και τέλος πραγματοποιήθηκε αριθμητική και ποιοτική σύγκριση των τριών μοντέλων που εκπαιδεύτηκαν.

Συνολικά η διαδικασία από την αρχική συλλογή των δεδομένων μέχρι τη διαδικασία της εκπαίδευσης των μοντέλων μηχανικής μάθησης περιγράφεται στο Σχήμα 6.1.

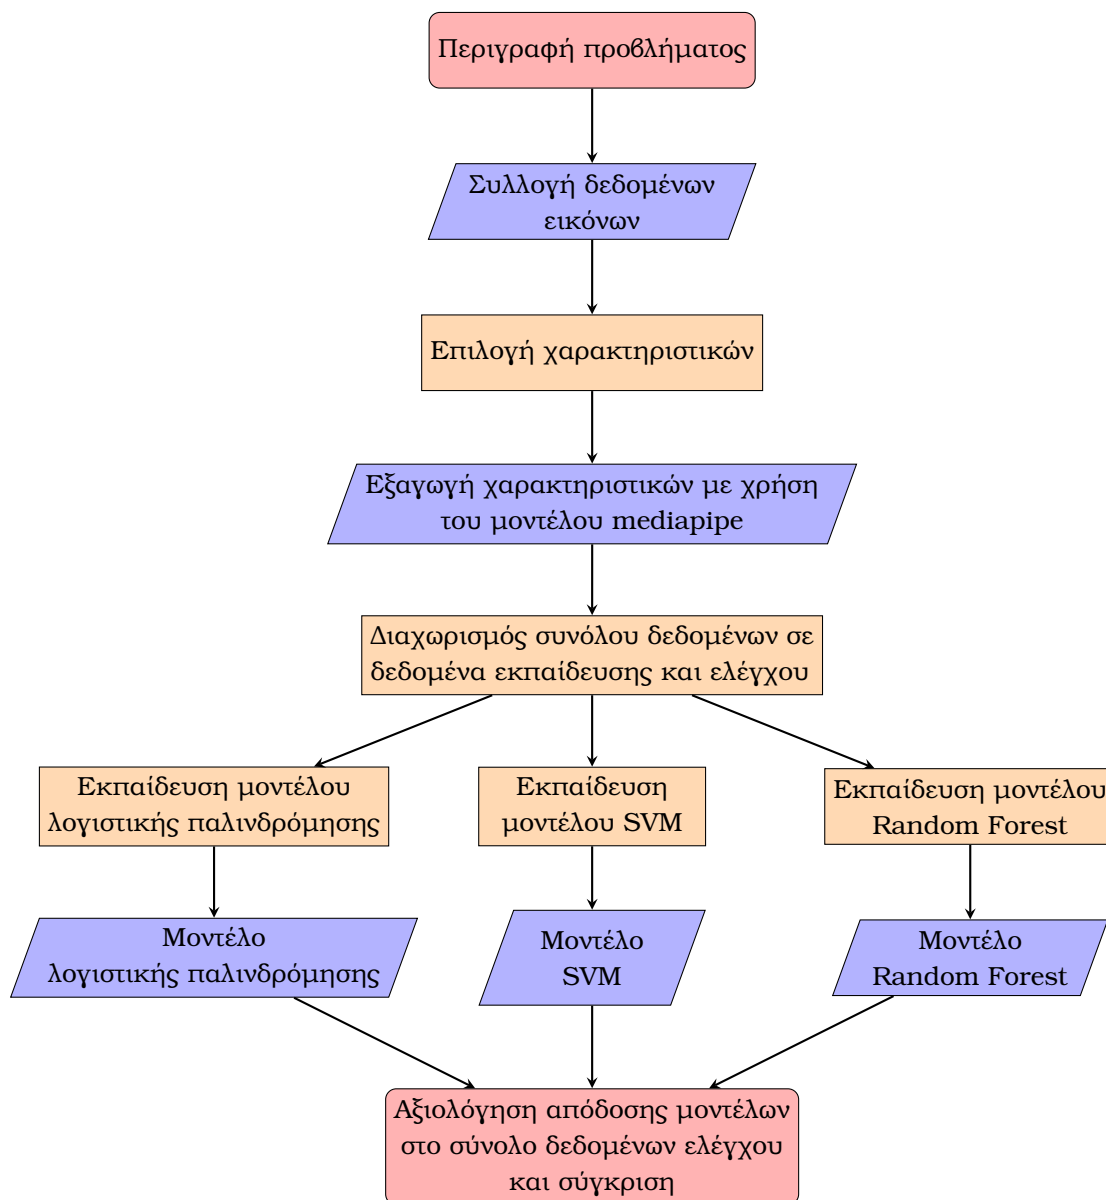
### 6.1 Μοντέλο λογιστικής παλινδρόμησης

Το μοντέλο της Λογιστικής Παλινδρόμησης εκπαιδεύτηκε κάνοντας χρήση όλων των αριθμητικών χαρακτηριστικών. Το σύνολο δεδομένων των συνολικά 95 παρατηρήσεων διαχωρίστηκε τυχαία και το 70% των παρατηρήσεων, χρησιμοποιήθηκε για την εκπαίδευση του μοντέλου ενώ το υπόλοιπο 30% χρησιμοποιήθηκε για τον έλεγχο της απόδοσης του μοντέλου όπως φαίνεται και στον πίνακα 6.1:

χρήση	ποσοστό παρατηρήσεων	πλήθος παρατηρήσεων
Εκπαίδευση μοντέλου	70%	67
Έλεγχος μοντέλου	30%	28
<b>Σύνολο</b>	100%	95

Πίνακας 6.1: Διαχωρισμός συνόλου δεδομένων σε δεδομένα εκπαίδευσης και ελέγχου του μοντέλου.

Στον Πίνακα 6.2 παρουσιάζεται ο Πίνακας Σύγχυσης (confusion matrix) των προβλέψεων του μοντέλου στο σύνολο δεδομένων ελέγχου.



Σχήμα 6.1: Διάγραμμα ροής εργασίας προεπεξεργασίας του συνόλου δεδομένων και εκπαίδευσης των μοντέλων Μηχανικής Μάθησης

		Προβλέψεις		σύνολο
		ΟΧΙ	ΝΑΙ	
Αντικειμενική αλήθεια	ΟΧΙ	13	3	16
	ΝΑΙ	1	12	13
σύνολο		14	15	

Πίνακας 6.2: Πίνακας Σύγκρισης μοντέλου Λογιστικής Παλινδρόμησης.

Στην περίπτωση της σκολίωσης μεγάλο πλήθος ψευδώς αρνητικών αποτελεσμάτων (False Negatives ή Type II Error) μπορεί να έχει αρνητικό αντίκτυπο στη χρησιμότητα του μοντέλου καθώς σημαίνει ότι το μοντέλο έχει προβλέψει ότι δεν υπάρχει σκολίωση ενώ στην πραγματικότητα ο εξεταζόμενος έχει σκολίωση. Στην περίπτωση αυτή το σύστημα δεν αναγνωρίζει εγκαίρως την σκολίωση με αποτέλεσμα ο ασθενής να έχει χειρότερη πρόγνωση και εξέλιξη της νόσου του. Αντίθετα τα ψευδώς θετικά αποτελέσματα (False positives ή Type I Error) δεν έχουν τον ίδιο αντίκτυπο καθώς το χειρότερο που μπορεί να συμβεί είναι ο εξεταζόμενος να παραπεμφθεί για επιπλέον εξετάσεις, όπως για παράδειγμα ακτινογραφία, ενώ στην πραγματικότητα δεν έχει σκολίωση, αλλά το σύστημα έκανε λανθασμένη πρόβλεψη ότι έχει. Στην τελευταία περίπτωση ο αντίκτυπος των ψευδώς θετικών αποτελεσμάτων είναι πολύ χαμηλότερος καθώς ο εξεταζόμενος απλά θα σπαταλήσει κάποιο επιπλέον χρόνο και χρήματα για την εκτέλεση των επιπλέον εξετάσεων ή θα λάβει λίγη επιπλέον ακτινοβολία για μία ακτινογραφία ενώ στη πραγματικότητα δε χρειαζόταν.

Στο μοντέλο της Λογιστικής Παλινδρόμησης που εκπαιδεύτηκε τα ψευδώς αρνητικά αποτελέσματα είναι λίγα, για την ακρίβεια μόνο ένα. Αντίστοιχα τα ψευδώς θετικά αποτελέσματα, τα οποία όμως δεν είναι το ίδιο κρίσιμα με τα ψευδώς αρνητικά, είναι επίσης λίγα. Η απόδοση του μοντέλου κρίνεται ικανοποιητική και αναλυτικά οι μετρικές αξιολόγησης του μοντέλου παρουσιάζονται στον Πίνακα 6.3.

Μετρική	Τιμή
Precision	0.80
Recall	0.92
F1-score	0.86
Accuracy	0.86

Πίνακας 6.3: Συγκεντρωτική αναφορά απόδοσης μοντέλου Λογιστικής Παλινδρόμησης.

## 6.2 Μοντέλο Μηχανών Διανυσμάτων Υποστήριξης

Για την εκπαίδευση του μοντέλου των Μηχανών Διανυσμάτων Υποστήριξης (SVM) πραγματοποιήθηκε διαχωρισμός του συνόλου δεδομένων σε δεδομένα εκπαίδευσης και ελέγχου σε ποσοστό 70%/30%. Στη συνέχεια μέσω της συνάρτησης GridSearchCV πραγματοποιήθηκε προσαρμογή 125 μοντέλων για τις ακόλουθες τιμές υπερπαραμέτρων: το C έλαβε τιμές 0.1, 1, 10, 100, 1000 το gamma 1, 0.1, 0.01, 0.001, 0.0001 και για πυρήνα επιλέχθηκε η τιμή rbf kernel.

Οι τιμές των υπερπαραμέτρων που έδωσαν την καλύτερη απόδοση στο μοντέλο μέσω της διασταυρούμενης επικύρωσης ήταν για το C η τιμή 100 και για το gamma η τιμή 0.01.

Στον πίνακα 6.4 βλέπουμε τον πίνακα σύγχυσης για το μοντέλο SVM.

		Προβλέψεις		σύνολο
		OXI	NAI	
Αντικειμενική αλήθεια	OXI	12	3	15
	NAI	2	12	14
σύνολο		14	15	

Πίνακας 6.4: Πίνακας σύγχυσης μοντέλου SVM.

και αντίστοιχα οι μετρικές αξιολόγησης του μοντέλου παρουσιάζονται στον πίνακα 6.5.

Μετρική	Τιμή
Precision	0.80
Recall	0.86
F1	0.83
Accuracy	0.83

Πίνακας 6.5: Συγκεντρωτική αναφορά απόδοσης μοντέλου SVM.

## 6.3 Μοντέλο Τυχαίου Δάσους

Για την εκπαίδευση του μοντέλου του Τυχαίου Δάσους πραγματοποιήθηκε διαχωρισμός του συνόλου δεδομένων σε δεδομένα εκπαίδευσης και ελέγχου ποσοστό 70%/30%. Η πα-



ράμετρος του  $n_{estimators}$  επιλέχθηκε ίση με 600, καθώς ένα μεγάλο πλήθος επιμέρους Δέντρων Απόφασης θα βοηθήσει στην αποφυγή φαινομένων υπερπροσαρμογής (overfitting). Το μέγιστο πλήθος χαρακτηριστικών που εξετάζονται σε κάθε διαίρεση κόμβου επιλέχθηκε να είναι ίσο με τη τετραγωνική ρίζα του πλήθους των χαρακτηριστικών που είναι 9. Ως κριτήριο για τον διαχωρισμό των κόμβων επιλέχθηκε η μετρική Gini Index.

Στον Πίνακα 6.6 παρουσιάζεται ο πίνακας σύγχυσης του μοντέλου Τυχαίου Δάσους.

		Προβλέψεις		σύνολο
		OXI	NAI	
Αντικειμενική αλήθεια	OXI	12	2	14
	NAI	0	15	15
σύνολο		12	17	

Πίνακας 6.6: Πίνακας σύγχυσης μοντέλου Τυχαίου Δάσους.

Φαίνεται ότι ο αλγόριθμος του Τυχαίου Δάσους παρουσίασε ιδιαίτερα καλή προβλεπτική ικανότητα καθώς δεν έδωσε καμία ψευδώς αρνητική πρόβλεψη που είναι σημαντικό να διατηρούνται λίγες στο πρόβλημα που εξετάζεται.

Συνολικά η αναφορά απόδοσης της ταξινόμησης του μοντέλου Τυχαίου Δάσους φαίνεται στον πίνακα 6.7.

Μετρική	Τιμή
Precision	0.88
Recall	1.00
F1	0.94
Accuracy	0.93

Πίνακας 6.7: Συγκεντρωτική αναφορά απόδοσης μοντέλου Τυχαίου Δάσους.

## 6.4 Σύγκριση μοντέλων

Στην παρούσα ενότητα πραγματοποιείται αριθμητική και ποιοτική σύγκριση των τριών μοντέλων που εκπαιδεύτηκαν και σχολιάζεται η προβλεπτική τους ικανότητα στην επίλυση του προβλήματος δυαδικής ταξινόμησης ατόμων σχετικά με την ύπαρξη ή όχι σκολίωσης.

### 6.4.1 Σύγκριση ακρίβειας μοντέλων

Αρχικά αξίζει να αναφερθεί ότι το σύνολο δεδομένων που χρησιμοποιήθηκε ήταν ισορροπημένο ως προς την μεταβλητή πρόβλεψης εάν δηλαδή υπάρχει σκολίωση ή όχι. Επομένως και οι παρατηρήσεις που χρησιμοποιήθηκαν για τον έλεγχο των τριών μοντέλων που εκπαιδεύθηκαν ήταν ισορροπημένες ως προς την κατηγορία πρόβλεψης, καθώς ο αλγόριθμος διαχωρισμού του συνόλου δεδομένων σε δεδομένα εκπαίδευσης και ελέγχου επιλέγει παρατηρήσεις με τυχαίο τρόπο.

Στον πίνακα 6.8 παρουσιάζονται συγκεντρωτικά οι μετρικές απόδοσης των τριών μοντέλων που εκπαιδεύτηκαν.

Μοντέλο	Precision	Recall	F1	Accuracy
Logistic Regression	0.80	0.92	0.86	0.86
SVM	0.80	0.86	0.83	0.83
Random Forest	0.88	1.00	0.94	0.93

Πίνακας 6.8: Μετρικές αξιολόγησης των τριών μοντέλων που εκπαιδεύτηκαν.

Για τη γενική αξιολόγηση των μοντέλων θα χρησιμοποιηθεί η μετρική αξιολόγησης F1-Score. Όπως φαίνεται και στον Πίνακα 6.8 το μοντέλο του Τυχαίου Δάσους παρουσίασε υψηλότερη απόδοση  $F1 - Score = 0.94$  με αρκετή διαφορά από τα υπόλοιπα δύο μοντέλα της Λογιστικής Παλινδρόμησης με  $F1 - Score = 0.86$  και των Μηχανών Διανυσμάτων Υποστήριξης με  $F1 - Score = 0.83$  που ακολουθούν με σχετικά μικρή μεταξύ τους διαφορά. Αντίστοιχα συμπεράσματα προκύπτουν εξετάζοντας και την μετρική Accuracy, κάτι μάλλον αναμενόμενο, καθώς οι κατηγορίες πρόβλεψης του συνόλου δεδομένων και των δεδομένων ελέγχου είναι ισορροπημένες ως προς το την κατηγορία της πρόβλεψης.

Στο συγκεκριμένο πρόβλημα, όπως αναφέρθηκε και στο Κεφάλαιο 2, οι Ψευδώς Αρνητικές προβλέψεις, είναι ιδιαίτερα σημαντικό να διατηρούνται σε χαμηλά επίπεδα καθώς μπορεί να οδηγήσουν σε μη έγκαιρη πρόγνωση της σκολίωσης με αρνητικές συνέπειες στην εξέλιξη της νόσου. Η μετρική Recall δίνει έμφαση στις Ψευδώς Αρνητικές παρατηρήσεις, με υψηλές τιμές της να σημαίνουν λιγότερες Ψευδώς Αρνητικές προβλέψεις. Φαίνεται ότι και ως προς τη μετρική Recall το μοντέλο που απέδωσε καλύτερα ήταν πάλι το Τυχαίο Δάσος με τιμή  $Recall = 1.00$  κάτι που σημαίνει ότι δεν έκανε καμία ψευδώς αρνητική πρόβλεψη, όπως άλλωστε παρουσιάζεται και στον Πίνακα σύγχυσης 6.6. Ακολουθεί το μοντέλο της Λογιστικής Παλινδρόμησης με  $Recall = 0.92$  και μία ψευδώς αρνητική πρόβλεψη και τέλος το μοντέλο των Μηχανών Διανυσμάτων Υποστήριξης με  $Recall = 0.86$  με δύο ψευδώς αρνητικές προβλέψεις.

Συμπερασματικά συνεκτιμώντας τις δύο μετρικές F1-Score και Recall φαίνεται ότι καλύτερα προσαρμόστηκε στα δεδομένα του προβλήματός μας το μοντέλο του Τυχαίου Δάσους, λιγότερο καλά το μοντέλο της Λογιστικής Παλινδρόμησης και ακόμη λιγότερο το μοντέλο των Μηχανών Διανυσμάτων Υποστήριξης.

### 6.4.2 Σύγκριση μοντέλων για την επιλογή χαρακτηριστικών

Το πρόβλημα που πραγματεύεται η παρούσα διπλωματική περιλαμβάνει την επιλογή και την εξαγωγή χαρακτηριστικών που έχουν επιλεγθεί με βάση τη βιβλιογραφία αλλά και το επιθυμητό αποτέλεσμα. Για τον λόγο αυτό είναι ωφέλιμο να χρησιμοποιήσουμε επεξηγηματικά μοντέλα Μηχανικής Μάθησης που παρέχουν τη δυνατότητα ποσοτικοποίησης της συνεισφοράς των διαφορετικών χαρακτηριστικών στην εκπαίδευση του μοντέλου και την προβλεπτική του ικανότητα.

Στο μοντέλο του Τυχαίου Δάσους προσφέρεται για τη μέτρηση της συνεισφοράς κάθε χαρακτηριστικού στην τελική πρόβλεψη. Η βιβλιοθήκη Sklearn που χρησιμοποιήθηκε παρέχει εργαλείο το οποίο μετρά τη σημασία κάθε χαρακτηριστικού εξετάζοντας πόσο οι κόμβοι δέντρων που χρησιμοποιούν αυτό το χαρακτηριστικό μειώνουν την εντροπία σε όλα τα δέντρα στο δάσος. Υπολογίζει ένα σκορ αυτόματα για κάθε χαρακτηριστικό μετά την εκπαίδευση και κλιμακώνει τα αποτελέσματα έτσι ώστε το άθροισμα όλων των τιμών συνεισφοράς να είναι ίσο με ένα. Κατόπιν σύγκρισης της συνεισφοράς των χαρακτηριστικών, μπορεί να επιλεγθεί κάποια χαρακτηριστικά να απορριφθούν, επειδή δεν συμβάλλουν αρκετά στη διαδικασία των προβλέψεων. Αυτό είναι σημαντικό καθώς όσο περισσότερα χαρακτηριστικά περιλαμβάνονται στην εκπαίδευση ενός μοντέλου τόσο πιο πιθανό είναι το μοντέλο να υποφέρει από υπερπροσαρμογή.

Πράγματι από τον Αλγόριθμο του Τυχαίου Δάσους προέκυψε ο Πίνακας 6.9 που παρουσιάζει τη συνεισφορά κάθε χαρακτηριστικού στις προβλέψεις.

Χαρακτηριστικό	Δείκτης συνεισφοράς
RPOL_AREA	0.197
LPOL_AREA	0.188
DVRVL	0.166
VL	0.145
HS	0.077
VSPINE	0.074
HH	0.054
AREA_DIFF	0.053
VR	0.045

Πίνακας 6.9: Ποσοτική μέτρηση της συνεισφοράς των διαφορετικών χαρακτηριστικών στην προβλεπτική ικανότητα του μοντέλου του Τυχαίου Δάσους.


Από τον πίνακα φαίνεται ότι εμβαδόν των πολυγώνων της πλάτης είναι σημαντικό χαρακτηριστικό με υψηλή συνεισφορά στην προβλεπτική ικανότητα ενώ αντίθετα η γωνία που σχηματίζεται από την ευθεία που ενώνει τον δεξιό ώμο με τον δεξιό μηρό και τον οριζόντιο άξονα VL, έχει μικρότερη συνεισφορά. Η παραπάνω διαδικασία μπορεί να χρησιμοποιηθεί, για να εξετασθούν ενδεχομένως νέα χαρακτηριστικά στη διαδικασία εξαγωγής χαρακτηριστι-

κών για την εκπαίδευση των αλγορίθμων με στόχο τη βελτίωση της συνολικής προβλεπτικής ικανότητας των μοντέλου.

Το μοντέλο της Λογιστικής Παλινδρόμησης παρομοίως είναι αρκετά επεξηγηματικό εξετάζοντας τον λόγο odds. Στο μοντέλο Λογιστικής Παλινδρόμησης που εκπαιδεύθηκε ο λόγος odds ισούται με:

$$\frac{P(y = 1)}{1 - P(y = 1)} = \frac{P(y = 1)}{P(y = 0)} = e^{0.0010 - 0.1391HS - 0.5948HH + 0.3985VL - 0.2215VR + 0.4192DVRVL - 0.1374VSPINE - 0.0048LPOL\_AREA + 0.0047RPOL\_AREA - 0.0026AREA\_DIFF} \quad (6.1)$$

Αν αυξηθεί η τιμή ενός χαρακτηριστικού κατά μία μονάδα, τότε ο λόγος odds θα μεταβληθεί σε ποσότητα ίση με το  $e$  υψωμένο δύναμη του βάρους του χαρακτηριστικού. Εφαρμόζοντας αυτόν τον κανόνα σε όλα τα χαρακτηριστικά προκύπτει η σημασία του κάθε χαρακτηριστικού όπως φαίνεται στο σχήμα 6.2. Στο σχήμα αυτό φαίνεται ότι η πρώτη τετράδα των πιο σημαντικών χαρακτηριστικών είναι η ίδια με αυτή που προέκυψε από το μοντέλο του Τυχαίου Δάσους.



Σχήμα 6.2: Διάγραμμα κατάταξης για τη σημαντικότητα των διαφορετικών χαρακτηριστικών στο μοντέλο της Λογιστικής Παλινδρόμησης

Το μοντέλο των Μηχανών Διανυσμάτων Υποστήριξης δεν παρέχει κάποιον επεξηγηματικό τρόπο κατάταξης των χαρακτηριστικών σύμφωνα με τη συνεισφορά τους.

### 6.4.3 Ποιοτική σύγκριση μοντέλων

Εκτός από τις μετρικές ακρίβειας και απόδοσης των μοντέλων και την επεξηγηματικότητα κάθε μοντέλου αξίζει να εξετασθούν τα ποιοτικά χαρακτηριστικά τους και πως αυτά επηρεάζουν την προσαρμογή τους στα δεδομένα του προβλήματος που εξετάζεται.

Το μοντέλο του Τυχαίου Δάσους είναι αρκετά ευέλικτο. Δεν προϋποθέτει την ύπαρξη γραμμικής σχέσης των δεδομένων όπως για παράδειγμα συμβαίνει στο μοντέλο της Λογιστικής Παλινδρόμησης ή στο μοντέλο των Μηχανών Διανυσμάτων Υποστήριξης που αντιπαρέχεται το εν λόγω πρόβλημα με τη χρήση Πυρήνων. Το μοντέλο του Τυχαίου δάσους παρουσιάζει επίσης μεγαλύτερη ανοχή σε φαινόμενα πολυσυγγραμμικότητας μεταξύ των διαφορετικών χαρακτηριστικών σε αντίθεση με το μοντέλο της Λογιστικής Παλινδρόμησης που δε λειτουργεί ικανοποιητικά όταν υπάρχει υψηλή συσχέτιση μεταξύ των χαρακτηριστικών. Στο συγκεκριμένο πρόβλημα υπάρχει υψηλή συσχέτιση μεταξύ των χαρακτηριστικών LPOL\_AREA και RPOL\_AREA και του μεγέθους DVRVL με το VSPINE.

Κατά την εκπαίδευση του μοντέλου της Λογιστικής Παλινδρόμησης πρέπει να δοθεί προσοχή στην επιλογή των χαρακτηριστικών καθώς αν περιληφθούν θορυβώδη χαρακτηριστικά που δε συνεισφέρουν σημαντικά στη πρόβλεψη μπορεί να μειωθεί η προβλεπτική ικανότητα του μοντέλου. Αντίστοιχα και ο αλγόριθμος των Μηχανών Διανυσμάτων Υποστήριξης μπορεί να παρουσιάσει ευαισθησία σε θορυβώδη δεδομένα, ενώ το Τυχαίο Δάσος δεν παρουσιάζει τόσο μεγάλη ευαισθησία σε θορυβώδη δεδομένα.

Τέλος, το μοντέλο της Λογιστικής Παλινδρόμησης κατά κανόνα χρειάζεται μεγαλύτερο πλήθος παρατηρήσεων για να εκπαιδευθεί σωστά και να μη παρουσιάζει φαινόμενα υπερπροσαρμογής. Ο αλγόριθμος του Τυχαίου Δάσους έχει μεγαλύτερη ανοχή σε φαινόμενα υπερπροσαρμογής ακόμη και με μικρότερο πλήθος παρατηρήσεων εκπαίδευσης. Αντίστοιχα και το μοντέλο των Μηχανών Διανυσμάτων Υποστήριξης λειτουργεί ικανοποιητικά και με λιγότερα δεδομένα εκπαίδευσης. Στο συγκεκριμένο πρόβλημα δε διατίθεται ιδιαίτερα μεγάλο σύνολο δεδομένων εκπαίδευσης επομένως τα μοντέλα των Μηχανών Διανυσμάτων Υποστήριξης και του Τυχαίου Δάσους μπορεί να λειτουργήσουν πιο ικανοποιητικά σε σχέση με το μοντέλο της Λογιστικής Παλινδρόμησης.



**Μέρος **

**Επίλογος**

---





## Κεφάλαιο 7

# Επίλογος

---

### 7.1 Συμπεράσματα

Η Ιδιοπαθής Σκολίωση είναι μια πάθηση που προκαλεί μη φυσιολογική καμπυλότητα της σπονδυλικής στήλης. Η εξέλιξη της ιδιοπαθούς σκολίωσης μπορεί να ξεκινήσει στο τέλος της παιδικής ηλικίας ή στην αρχή της εφηβίας και εξελίσσεται μέχρι ένα παιδί να ενηλικιωθεί. Η έγκαιρη διάγνωση της σκολίωσης παίζει καθοριστικό ρόλο στη μετέπειτα εξέλιξη της νόσου αλλά και στην ποιότητα ζωής των ασθενών.

Στην παρούσα διπλωματική εργασία έγινε ανάπτυξη ενός συστήματος Μηχανικής Μάθησης δυαδικής ταξινόμησης με σκοπό την έγκαιρη διάγνωση της σκολίωσης αξιολογώντας φωτογραφίες πλάτης των εξεταζόμενων ατόμων.

Αρχικά, με χρήση της τεχνικής web scraping δημιουργήθηκε ένα σύνολο δεδομένων με φωτογραφίες της πλάτης ασθενών με σκολίωση και υγιών ατόμων.

Κατόπιν, έγινε μελέτη της βιβλιογραφίας σχετικά με την αξιολόγηση της σκολίωσης σε φωτογραφίες δύο διαστάσεων που περιελάμβαναν την πλάτη των ασθενών. Με βάση τη βιβλιογραφία και τις ανάγκες του μοντέλου έγινε η επιλογή των αριθμητικών χαρακτηριστικών που κρίθηκαν χρήσιμα για την αξιολόγηση της σκολίωσης. Με τη βοήθεια της βιβλιοθήκης mediapipe καθορίστηκε στην εικόνα της πλάτης κάθε εξεταζόμενου το τετράπλευρο με κορυφές τους ώμους και τους μηρούς του. Στη συνέχεια έγινε υπολογισμός των χαρακτηριστικών και πιο συγκεκριμένα της γωνίας που σχηματίζεται από όλα τα ευθύγραμμα τμήματα αυτού του τετραπλεύρου με τον οριζόντιο άξονα και υπολογίστηκε η ευθεία που ενώνει τα μέσα των ευθύγραμμων τμημάτων των ώμων και των μηρών. Τέλος υπολογίστηκε το εμβαδόν των δύο τετράπλευρων που σχηματίστηκαν έπειτα από τη χάραξη της ευθείας αυτής.

Τα αριθμητικά χαρακτηριστικά που υπολογίστηκαν αφού διαχωρίστηκαν σε σύνολο δεδομένων εκπαίδευσης και σύνολο δεδομένων ελέγχου με αναλογία 70%/30% χρησιμοποιήθηκαν για την εκπαίδευση και την αξιολόγηση τριών μοντέλων μηχανικής μάθησης δυαδικής ταξινόμησης: της Λογιστικής Παλινδρόμησης, των Μηχανών Διανυσμάτων Υποστήριξης και του Τυχαίου Δάσους. Αφού ολοκληρώθηκε η εκπαίδευσή τους, η αξιολόγηση και των τριών μοντέλων έδειξε ότι διαθέτουν υψηλή προβλεπτική ικανότητα στην διάγνωση της σκολίωσης, καθώς πετυχαίνουν υψηλή ακρίβεια όπως αυτή ποσοτικοποιείται στη μετρική F1-Score. Πιο συγκεκριμένα το μοντέλο του Τυχαίου Δάσους πέτυχε  $F1 - Score = 0.94$  ενώ της Λογιστικής Παλινδρόμησης και των Μηχανών Διανυσμάτων Υποστήριξης 0.86 και 0.83 αντίστοιχα.

Η μετρική Recall χρησιμοποιήθηκε για την αξιολόγηση των ψευδώς αρνητικών προβλέψε-

ων που έχουν υψηλό αρνητικό αντίκτυπο στην έγκαιρη διάγνωση και εξέλιξη της νόσου. Φάνηκε ότι το μοντέλο του Τυχαίου Δάσους πετυχαίνει πολύ υψηλή τιμή στη μετρική Recall ίση με 1, καθώς δεν έδωσε ούτε μία ψευδώς αρνητική πρόβλεψη, ενώ ακολουθούν τα μοντέλα της Λογιστικής Παλινδρόμησης και των Μηχανών Διανυσμάτων Υποστήριξης με τιμές στη μετρική Recall 0.92 και 0.86 αντίστοιχα.

Με τη βοήθεια των μοντέλων της Λογιστικής Παλινδρόμησης και του Τυχαίου Δάσους, που παρέχουν ικανοποιητική επεξηγηματικότητα, ποσοτικοποιήθηκε η συνεισφορά όλων των χαρακτηριστικών στην τελική πρόβλεψη. Φάνηκε ότι μεγαλύτερη συνεισφορά στις τελικές προβλέψεις είχαν τα χαρακτηριστικά που ποσοτικοποιούν το εμβαδό των δύο πολυγώνων που σχηματίζονται εάν στο πολύγωνο με κορυφές τους ώμους και τους μηρούς του ανθρώπου φέρουμε την ευθεία που ενώνει το μέσο των ευθύγραμμων τμημάτων που ενώνουν τους ώμους και τους μηρούς, όπως επίσης και η γωνία που σχηματίζεται από το ευθύγραμμο τμήμα που ενώνει τους μηρούς με τον οριζόντιο άξονα. Τα αποτελέσματα της συνεισφοράς των χαρακτηριστικών στην τελική πρόβλεψη ήταν σημαντικά για την αξιολόγηση της διαδικασίας επιλογής χαρακτηριστικών.

Τέλος αφού πραγματοποιήθηκε συγκριτική αξιολόγηση των ποιοτικών χαρακτηριστικών των εν λόγω μοντέλων, και λαμβάνοντας υπόψη τη φύση των δεδομένων του προβλήματος της διπλωματικής, φάνηκε ότι το μοντέλο του Τυχαίου Δάσους προσαρμόστηκε αρκετά καλά, καθώς μπορεί να εκπαιδευτεί με μικρό πλήθος παρατηρήσεων, έχει υψηλή ανθεκτικότητα σε φαινόμενα υπερπροσαρμογής και διαθέτει ανοχή σε περιπτώσεις που υπάρχει υψηλή συσχέτιση μεταξύ των χαρακτηριστικών του συνόλου δεδομένων.

Συμπερασματικά μπορούμε να πούμε ότι κατέστη εφικτό με χρήση τεχνικών Μηχανικής Μάθησης για γίνει διάγνωση της σκολίωσης σε φωτογραφίες πλάτης ατόμων, με αρκετά υψηλή ακρίβεια.

## 7.2 Μελλοντικές Επεκτάσεις

Για την αξιολόγηση της σκολίωσης, στην παρούσα διπλωματική, χρησιμοποιήθηκαν οι δυαδικοί ταξινομητές της Λογιστικής Παλινδρόμησης των Μηχανών Διανυσμάτων Υποστήριξης και του Τυχαίου Δάσους. Η προβλεπτική ικανότητα των μοντέλων που εκπαιδεύτηκαν και η δυνατότητα γενίκευσης τους μπορούν να βελτιωθούν με ορισμένες παρεμβάσεις.

Η αύξηση του μεγέθους του συνόλου δεδομένων θα μπορούσε να βοηθήσει στη βελτίωση της ικανότητας γενίκευσης των μοντέλων, καθώς όσο περισσότερα δεδομένα χρησιμοποιούνται κατά τη φάση της εκπαίδευσης τόσο το μοντέλο μπορεί να ανταποκριθεί καλύτερα σε περισσότερες περιπτώσεις και να έχει χαμηλότερες πιθανότητες υπερπροσαρμογής στο σύνολο δεδομένων. Θα μπορούσε ακόμη στο σύνολο δεδομένων να ενσωματωθούν εικόνες με ασθενείς σε πολύ πρώιμο στάδιο εμφάνισης της σκολίωσης, επομένως οι ταξινομητές να είναι σε θέση να αναγνωρίζουν με μεγαλύτερη ευαισθησία την εμφάνιση της νόσου σε πιο πρώιμο στάδιο.

Η διαδικασία της επιλογής και εξαγωγής των χαρακτηριστικών μπορεί επίσης να βελτιωθεί. Εκτός από τη βιβλιοθήκη *mediapipe* που χρησιμοποιήθηκε για την εξαγωγή των χαρακτηριστικών θα μπορούσε να γίνει δοκιμή επιπλέον βιβλιοθηκών εκτίμησης της στάσης του σώματος (*Posture Estimation*), καθώς επίσης να δοκιμαστούν επιπλέον τεχνικές επε-

ξεργασίας εικόνας για την εξαγωγή χαρακτηριστικών όπως για παράδειγμα η εκτίμηση του περιγράμματος της πλάτης του εξεταζόμενου.

Οι προβλέψεις των δυαδικών ταξινομητών που χρησιμοποιήκαν στην παρούσα διπλωματική, δίνουν απάντηση (ΝΑΙ/ΟΧΙ) στο ερώτημα εάν ο εξεταζόμενος άνθρωπος σε μία φωτογραφία έχει σκολίωση ή όχι. Στις περιπτώσεις ύπαρξης σκολίωσης όμως δε ποσοτικοποιούν το στάδιο εξέλιξης της νόσου και τη βαρύτητα της. Ως μελλοντική επέκταση της διπλωματικής εργασίας μπορεί να υλοποιηθεί ένα μοντέλο μηχανικής μάθησης ταξινόμησης πολλαπλών κατηγοριών (multi class classification) το οποίο να ταξινομεί τις εικόνες σε διαφορετικές κατηγορίες όπως για παράδειγμα: "χωρίς σκολίωση", "πρώιμο στάδιο σκολίωσης", "προχωρημένο στάδιο σκολίωσης", "βαρύτερη μορφή σκολίωσης".

Θα μπορούσε ακόμη να εκπαιδευθεί μοντέλο Μηχανικής Μάθησης γραμμικής παλινδρόμησης που με βάση τη εικόνα της πλάτης ενός ασθενή να υπολογίζει κάποια αριθμητική τιμή που θα προσδιορίζει τη βαρύτητα της νόσου όπως για παράδειγμα τη γωνία Cobb. Κάτι τέτοιο βέβαια απαιτεί τη δημιουργία ενός συνόλου δεδομένων με περισσότερες πληροφορίες, που θα περιλαμβάνει για παράδειγμα, εκτός από τη φωτογραφία της πλάτης του εξεταζόμενου και τη γωνία Cobb της σπονδυλικής στήλης του ασθενή, της οποίας ο υπολογισμός απαιτεί συνήθως τη λήψη ακτινογραφίας.

Τέλος, για την εκπαίδευση του συστήματος μηχανικής μάθησης αντί για φωτογραφίες δύο διαστάσεων της πλάτης των εξεταζόμενων θα μπορούσαν να ληφθούν τρισδιάστατες απεικονίσεις της μορφολογίας της πλάτης. Οι τρισδιάστατες απεικονίσεις αντί για εικονοστοιχεία σιτιβ δισδιάστατο χώρο αποτελούνται από νέφη σημείων στον τρισδιάστατο χώρο με κάθε σημείο να χαρακτηρίζεται από τις καρτεσιανές συντεταγμένες του ( $X$ ,  $Y$ ,  $Z$ ). Τα τρισδιάστατα νέφη σημείων (3d point clouds) παράγονται από τρισδιάστατους σαρωτές με διάφορες τεχνικές όπως για παράδειγμα τη τεχνική LiDAR (Light Detection And Ranging) η οποία βασίζεται στην εκπομπή παλμικής ακτινοβολίας λέιζερ στο περιβάλλον και ακολούθως, στην καταγραφή της οπισθοσκεδαζόμενης ακτινοβολίας λέιζερ για την εκτίμηση της απόστασης κάθε στοιχείου του χώρου από τον σαρωτή.

Μία τρισδιάστατη απεικόνιση σημείων περιλαμβάνει περισσότερες πληροφορίες σχετικά με τη μορφολογία της πλάτης ενός εξεταζόμενου συγκριτικά με μία δισδιάστατη εικόνα. Επομένως μπορεί να προσφέρει πολύ μεγαλύτερη ακρίβεια και ευαισθησία σε μοντέλα Μηχανικής Μάθησης που ενδεχομένως θα μπορούσαν να προβλέψουν την ακριβή γωνία Cobb μέσω γραμμικής παλινδρόμησης. Η ενσωμάτωση αισθητήρων LiDAR σε αρκετά κινητά τηλέφωνα τελευταίας τεχνολογίας, καθιστά ακόμη πιο προσβάσιμη την τεχνολογία αυτή. Μελέτες όπως η [18] έχουν προσπαθήσει μέσω του υπολογισμού ενός δείκτη ασυμμετρίας της πλάτης ο οποίος βασίζεται σε νέφη σημείων στον τρισδιάστατο χώρο που δημιουργήθηκαν με έναν τρισδιάστατο σαρωτή, να υπολογίσουν τη γωνία Cobb.



## Βιβλιογραφία

---

- [1] Chen Jin, Shengru Wang, Guodong Yang, En Li και Zize Liang. *A Review of the Methods on Cobb Angle Measurements for Spinal Curvature*. *Sensors*, 22(9), 2022.
- [2] Juan Bago, Javier Pizones, Antonia Matamalas και Elisa D'Agata. *Clinical photography in severe idiopathic scoliosis candidate for surgery: is it a useful tool to differentiate among Lenke patterns?* *Eur Spine J*, 28(12):3018-3025, 2019.
- [3] Antonia Matamalas, Juan Bagó, Elisabetta D Agata και Ferran Pellisé. *Validity and reliability of photographic measures to evaluate waistline asymmetry in idiopathic scoliosis*. *Eur Spine J*, 25(10):3170-3179, 2016.
- [4] Hans Rudolf Weiss. *Spinal deformities rehabilitation - state of the art review*. *Scoliosis*, 5:28, 2010.
- [5] Max Aebi. *The adult scoliosis*. *European Spine Journal*, 14(10):925-948, 2005.
- [6] *Scoliosis symptoms*. <https://www.ucsfhealth.org/conditions/scoliosis/symptoms/>. Ημερομηνία Πρόσβασης: 2023-01-13.
- [7] Angela L Kuznia, Anita K Hernandez και Lydia U Lee. *Adolescent Idiopathic Scoliosis: Common Questions and Answers*. *Am Fam Physician*, 101(1):19-23, 2020.
- [8] Vidyadhar V Upasani, Christine Caltoun, Maty Petcharaporn, Tracey P Bastrom, Jeff B Pawelek, Randal R Betz, David H Clements, Lawrence G Lenke, Thomas G Lowe και Peter O Newton. *Adolescent idiopathic scoliosis patients report increased pain at five years compared with two years after surgical treatment*. *Spine (Phila Pa 1976)*, 33(10):1107-1112, 2008.
- [9] J Martínez-Llorens, M Ramírez, M J Colomina, J Bagó, A Molina, E Cáceres και J Gea. *Muscle dysfunction and exercise limitation in adolescent idiopathic scoliosis*. *Eur Respir J*, 36(2):393-400, 2009.
- [10] N Kahanovitz, B Snow και I Pinter. *The comparative results of psychologic testing in scoliosis patients treated with electrical stimulation or bracing*. *Spine (Phila Pa 1976)*, 9(5):442-444, 1984.
- [11] *The 6 Assumptions of Logistic Regression (With Examples)*. <https://www.statology.org/assumptions-of-logistic-regression/>. Ημερομηνία Πρόσβασης: 2023-01-13.
- [12] Esperanza Camargo, Johan Malagón και Francisco Hurtado. *Design and Implementation of a Portable Digital Scoliometer*. *VI Latin American Congress on Biomedical*

- Engineering CLAIB 2014, Paraná, Argentina 29, 30 & 31 October 2014* Ariel Braidot και Alejandro Hadad, επιμελητές, σελίδες 111–112, Cham, 2015. Springer International Publishing.
- [13] Chao Chen, Ronghua Yu, Wei Xu, Zhikun Li, Yifan Li, Ruixi Hu και Xiaodong Zhu. *A Practical Study of Diagnostic Accuracy: Scoliosis Screenings of Middle School Students by a Trained Nurse With a Smartphone Versus a Spine Surgeon With a Scoliometer. Spine (Phila Pa 1976)*, 45(5):E266–E271, 2020.
- [14] Mohammad Fraiwan. *A dataset of scoliosis, spondylolisthesis, and normal vertebrae X-ray images*, 2022.
- [15] Mohamed Elgendy. *Deep learning for vision systems*. Simon and Schuster, 2020.
- [16] Nati Ofir και Jean Christophe Nebel. *Classic versus deep learning approaches to address computer vision challenges*. 2021.
- [17] Camillo Lugaresi, Jiuqiang Tang, Hadon Nash, Chris McClanahan, Esha Uboweja, Michael Hays, Fan Zhang, Chuo Ling Chang, Ming Guang Yong, Juhyun Lee, Wan Teh Chang, Wei Hua, Manfred Georg και Matthias Grundmann. *MediaPipe: A Framework for Building Perception Pipelines*. 2019.
- [18] Terufumi Kokabu, Noriaki Kawakami, Koki Uno, Toshiaki Kotani, Teppei Suzuki, Yuichiro Abe, Kenichiro Maeda, Fujio Inage, Yoichi M. Ito, Norimasa Iwasaki και Hideki Sudo. *Three-dimensional depth sensor imaging to identify adolescent idiopathic scoliosis: a prospective multicenter cohort study. Scientific Reports*, 9(1):9678, 2019.

## Απόδοση ξενόγλωσσων όρων

---

### Απόδοση

Μηχανική Μάθηση  
Επιβλεπόμενη Μηχανική Μάθηση  
Μη επιβλεπόμενη Μηχανική Μάθηση  
Ενισχυτική Μάθηση  
Γραμμική Παλινδρόμηση  
Λογιστική Παλινδρόμηση  
Δένδρα Αποφάσεων  
Νευρωνικά Δίκτυα  
Τυχαίο Δάσος  
Μηχανές Διανυσμάτων Υποστήριξης  
Υπερπροσαρμογή  
Διασταυρούμενη επικύρωση  
Πίνακας Σύγχυσης

### Ξενόγλωσσος όρος

Machine Learning  
Supervised Machine Learning  
Unsupervised learning  
Reinforcement Learning  
Linear Regression  
Logistic Regression  
Decision Trees  
Neural Networks  
Random Forest  
Support Vector Machines  
overfitting  
Cross validation  
Confusion Matrix

