



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ
ΥΠΟΛΟΓΙΣΤΩΝ

Διάγνωση εξ επαφής αλλεργικής δερματίτιδας με Χρήση Μηχανικής Μάθησης

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

ΤΟΥ

Παναγιωτίδη Σ. Κυριάκου

Επιβλέπων : Γεώργιος Ματσόπουλος

Καθηγητής ΕΜΠ

Αθήνα, Ιούνιος 2023



ΕΘΝΙΚΟ ΜΕΤΣΟΒΙΟ ΠΟΛΥΤΕΧΝΕΙΟ
ΣΧΟΛΗ ΗΛΕΚΤΡΟΛΟΓΩΝ ΜΗΧΑΝΙΚΩΝ ΚΑΙ ΜΗΧΑΝΙΚΩΝ
ΥΠΟΛΟΓΙΣΤΩΝ

Διάγνωση εξ επαφής αλλεργικής δερματίτιδας με Χρήση Μηχανικής Μάθησης

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

ΤΟΥ

Παναγιωτίδη Σ. Κυριάκου

Επιβλέπων : Γεωργιος Ματσόπουλος

Καθηγητής ΕΜΠ

Εγκρίθηκε από την κάτωθι τριμελή επιτροπή την 29 Ιουνίου 2023.

Δημήτριος Κουτσούρης

Καθηγητής

Γεώργιος Ματσόπουλος

Καθηγητής

Παναγιώτης Τσανάκας

Καθηγητής

Παναγιωτίδης Σ. Κυριάκος

Διπλωματούχος Ηλεκτρολόγος Μηχανικός και Μηχανικός Υπολογιστών ΕΜΠ

Copyright © Παναγιωτίδης Σ. Κυριάκος, 2023

Με επιφύλαξη παντός δικαιώματος. All rights reserved.

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. Ερωτήματα που αφορούν τη χρήση της εργασίας για κερδοσκοπικό σκοπό πρέπει να απευθύνονται προς τον συγγραφέα. Οι απόψεις και τα συμπεράσματα που περιέχονται σε αυτό το έγγραφο εκφράζουν τον συγγραφέα και δεν πρέπει να ερμηνευθεί ότι αντιπροσωπεύουν τις επίσημες θέσεις του Εθνικού Μετσόβιου Πολυτεχνείου

Ευχαριστίες

Αρχικά, νιώθω την υποχρέωση να ευχαριστήσω τον Καθηγητή κ. Γεώργιο Ματσόπουλο για την ανάθεση και την εμπιστοσύνη του σε ένα τόσο ενδιαφέρον και πρωτοποριακό θέμα. Επίσης θα ήθελα να εκφράσω τις θερμές ευχαριστίες μου στην υπόλοιπη τριμελή επιτροπή, καθ. κ. Δημήτριο Κουτσούρη και καθ. κ. Παναγιώτη Τσανάκα, καθώς και στη δερματολογική κλινική του νοσοκομείου που συνέβαλε και ανταποκρίθηκε σε όποια βοήθεια και πληροφορία ζητήθηκε. Τέλος, θα ήθελα να ευχαριστήσω θερμά τον Υποψήφιο Διδάκτορα κ. Ιωάννη Βεζάκη για την συνεχή βοήθεια και την πολύτιμη καθοδήγηση καθόλη την διάρκεια της εκπόνησης αυτής της εργασίας.

Παναγιωτίδης Κυριάκος, Αθήνα, Ιούνιος 2023

Περίληψη

Η δερματίτιδα αποτελεί μια κοινή δερματική πάθηση που επηρεάζει εκατομμύρια ανθρώπους σε όλο τον κόσμο. Η ύπαρξη διάφορων τύπων και μεθόδων διάγνωσης καθιστούν τόσο την αναγνώριση όσο και την θεραπεία δύσκολα προβλήματα για την επιστημονική κοινότητα. Ο κυριότερος τρόπος διάγνωσης σήμερα γίνεται μέσω της χρήσης επιθέματος και της αξιολόγησης της αντίδρασης του δέρματος με διάφορες ουσίες με σκοπό την αναγνώριση τόσο του τύπου αλλά και της έντασης της ασθένειας. Η παραπάνω διαδικασία ωστόσο, βασίζεται κατά κύριο λόγο στην ικανότητα και την υποκειμενική γνώμη του εξετάζοντος ιατρού, πράγμα που τον καθιστά απαραίτητο και μοναδικό υπόλογο για την διάγνωση της ασθένειας.

Η ανάπτυξη της όρασης υπολογιστών και της μηχανικής μάθησης στον τομέα της υγείας τα τελευταία χρόνια έχει οδηγήσει στην αυτοματοποίηση παρόμοιων προβλημάτων. Η εξαγωγή χαρακτηριστικών από εικόνες και εκπαίδευση αντίστοιχων «παραδοσιακών» και βαθιάς μηχανικής μάθησης μοντέλων έχει αποδειχθεί, από πολλές σύγχρονες μελέτες, αξιόπιστο εργαλείο για την διάγνωση πολλών ασθενειών με μεγάλα ποσοστά ακρίβειας. Η ίδια φιλοσοφία μπορεί να ακολουθηθεί και στην περίπτωση της δερματίτιδας. Στο πλαίσιο αυτό στην Α΄ Πανεπιστημιακή Κλινική Δερματολογικών και Αφροδίσιων Νοσημάτων (ΑΠΚΔΑΝ), Νοσοκομείο Ανδreas Συγγρός, πραγματοποιήθηκε δειγματοληπτική διαδικασία και συγκεντρώθηκαν δείγματα και εικόνες δερματίτιδας από 200 ασθενείς.

Η συγκεκριμένη ερευνητική διαδικασία στοχεύει στην εκμετάλλευση της δυνατότητας της μηχανικής, και πιο συγκεκριμένα της βαθιάς μάθησης, με την οποία μπορούν να εξαχθούν χαρακτηριστικά αναγνώρισης της δερματίτιδας. Στο πλαίσιο της διπλωματικής εργασίας εξετάστηκαν και αναπτύχθηκαν διάφορα μοντέλα μηχανικής μάθησης τα όποια κατάφεραν να πετύχουν υψηλά ποσοστά ακρίβειας. Έτσι εν δυνάμει, ένας τέτοιος αλγόριθμος θα μπορούσε να χρησιμοποιηθεί ως βοηθητικός διαγνωστικός μηχανισμός, παρέχοντας ενδεικτική γνωμάτευση δερματικών παθήσεων από απομονωμένα ιατρεία είτε σε οικιακή χρήση. Επιπλέον θα μπορούσε να χρησιμοποιηθεί σε συμβουλευτικό ρόλο, ως εργαλείο, από τους ίδιους τους γιατρούς τόσο για ασφαλέστερη πρόληψη όσο και για αντιμετώπιση των εν λόγω παθήσεων. Τα αποτελέσματα της παραπάνω μελέτης αποδείχθηκαν αρκετά υποσχόμενα και η χρήση της μηχανικής μάθησης για τον εντοπισμό δερματίτιδας αποτελεί ένα πρόσφορο έδαφος για την ανάπτυξη εφαρμογών αλλά και την βελτιστοποίηση της ανίχνευσης και της αντιμετώπισης της νόσου.

Λέξεις-κλειδιά : Δερματίτιδα, Νευρωνικά Δίκτυα, Μηχανική Μάθηση, Συνελικτικά Νευρωνικά Δίκτυα, Βαθιά Μηχανική Μάθηση, Επεξεργασία Εικόνων, Εξαγωγή Χαρακτηριστικών από Εικόνες

Abstract

Dermatitis, commonly referred to as eczema, is a prevalent skin disorder with a global impact. Within the scientific community, accurate diagnosis and effective treatment of dermatitis are hindered by the intricate nature and diverse manifestations of the condition, as well as the wide range of diagnostic techniques employed. The predominant approach for diagnosis currently involves patch testing, whereby the skin's response to various chemical substances is assessed to determine the specific type and severity of the dermatitis. However, due to its heavy reliance on the expertise and subjective judgment of the examining physician, the responsibility for diagnosing the disease lies solely with them.

Recent advancements in computer vision and machine learning within the healthcare field have paved the way for automating comparable diagnostic challenges. It has been well-established that extracting distinctive features from images and training both "traditional" and deep machine learning models yield reliable and accurate outcomes in diagnosing a diverse range of diseases. The same paradigm can be applied to dermatitis. In this context, a comprehensive sampling procedure was conducted at the University Clinic of Dermatology and Venereal Diseases in Andreas Syngros Hospital, involving the collection of samples and images of dermatitis from a cohort of 200 patients.

The primary objective of this thesis is to explore the potential of engineering, specifically deep learning techniques, in extracting discriminative features for dermatitis recognition. Through extensive examination and development of various machine learning models, substantial progress has been made in achieving high levels of accuracy. Consequently, these algorithms hold the potential to serve as supplementary diagnostic tools, offering indicative evaluations of skin conditions in isolated clinic settings or even for personal use. Furthermore, they can be utilized as consultative aids by healthcare professionals to enhance both preventive strategies and treatment plans for dermatitis. The outcomes of this study have demonstrated considerable promise, underscoring the fertile ground for machine learning applications in dermatitis detection and disease management.

In conclusion, the findings of this research highlight the potential of machine learning, particularly deep learning methodologies, in automating the identification of dermatitis. By harnessing the power of computer vision and machine learning techniques, the field of dermatology stands to benefit from improved diagnostic accuracy and optimized disease management practices. These results pave the way for further advancements in the development and refinement of applications in the realm of dermatology.

Keywords: Dermatitis, Neural Networks, Machine Learning, Convolutional Neural Networks, Deep Machine Learning, Image Processing, Image Feature Extraction

Περιεχόμενα

Κεφάλαιο 1. Δερματίτιδα και Μηχανική Μάθηση	19
1.1 Εισαγωγή	19
1.2 Δερματίτιδα	19
1.3 Τύποι Δερματίτιδας	20
1.4 Ανίχνευση	21
1.5 Πρόληψη και θεραπεία.....	23
1.6 Επιπολασμός δερματίτιδας	24
1.7 State of the art in ML	25
Κεφάλαιο 2. Ασθενείς και συλλογή δεδομένων	28
2.1 Εισαγωγή	28
2.2 Διαδικασία εξέτασης.....	28
2.3 Metadata	30
2.4 Antera 3D κάμερα	31
Κεφάλαιο 3. Επεξεργασία εικόνων	35
3.1 Όραση Υπολογιστών.....	35
3.2 Χαρακτηριστικά εικόνων.....	36
3.3 Χρωματικοί χώροι	39
3.3.1 Χρώμα και ανθρώπινο μάτι.....	39
3.3.2 Γραμμικοί χώροι χρώματος.....	40
3.3.3 Μη-γραμμικοί χώροι χρώματος	41
Κεφάλαιο 4. Εξαγωγή και επεξεργασία δεδομένων	43
4.1 Εισαγωγή	43
4.2 Εξαγωγή δεδομένων	43
4.3 Εξισορρόπηση συνόλου δεδομένων	44
Κεφάλαιο 5. Νευρωνικά Δίκτυα και Μηχανική Μάθηση	47
5.1 Εισαγωγή	47
5.2 Κατηγορίες μηχανικής μάθησης	48
5.2.1 Εποπτευόμενη μάθηση	49
5.2.2 Μάθηση χωρίς επίβλεψη	50
5.2.3 Ενισχυτική Μάθηση	51
5.3 Μοντέλα Μηχανικής Μάθησης.....	52
5.3.1 Decision Tree	52

5.3.2 Random Forest	53
5.3.3 Support Vector machines	54
5.3.4 K Nearest Neighbors.....	55
5.3.5 Xgboost.....	56
Κεφάλαιο 6. Βαθιά Μάθηση και Συνδυασμός Μεθόδων.....	59
6.1 Deep Learning.....	59
6.2 Νευρωνικά Δίκτυα.....	59
6.2.1 Ιδιότητες νευρωνικών δικτύων	60
6.2.2 Τύποι συνάρτησης ενεργοποίησης.....	61
6.3 CNNs	63
6.5 CNN and traditional Machine learning fusion algorithms.....	65
6.6 Παραδείγματα και εφαρμογές γύρω από των τον συνδυασμό μεθόδων στην μηχανική μάθηση	66
Κεφάλαιο 7. Μεθοδολογία	69
7.1 Εισαγωγή	69
7.2 Διαχωρισμός δεδομένων	70
7.3 Μετρικές Αξιολόγησης	71
7.4 Βασικοί αλγόριθμοι Μηχανικής Μάθησης	72
7.5 Συνελικτικά δίκτυα	73
7.6 Συνδυασμός μεθόδων.....	74
Κεφάλαιο 8. Αποτελέσματα	77
8.1 Βασικοί αλγόριθμοι Μηχανικής Μάθησης	77
8.2 Βασικοί αλγόριθμοι Μηχανικής Μάθησης	77
8.2 Συνελικτικά δίκτυα	83
8.3 Συνδυασμός μεθόδων.....	88
8.4 Ανάλυση αποτελεσμάτων.....	92
Κεφάλαιο 9. Συμπεράσματα	97
9.1 Εισαγωγή	97
9.2 Ανάλυση των μελλοντικών βημάτων	97
Βιβλιογραφία	100

Κατάλογος Σχημάτων

<i>Εικόνα 1: Αντίδραση του δέρματος στις ουσίες του NACDG από 1 έως 20 [10].....</i>	22
<i>Εικόνα 2: Αντίδραση του δέρματος στις ουσίες του NACDG από 21 έως 50 [10].....</i>	23
<i>Εικόνα 3: Χάρτης εξάπλωσης δερματίτιδας[14]</i>	25
<i>Εικόνα 4: Χωροταξική τοποθέτηση των περιοχών του εφαρμοσμένου έμπλαστρου.....</i>	29
<i>Εικόνα 5 : Στην πάνω γραμμή από αριστερά από τα δεξιά αντιστοιχούν, 1 Χρώμα, 2. Λεπτές γραμμές 3. Πτυχωσεις και στην κάτω γραμμή από αριστερά από τα δεξιά 4. Ερυθρότητα 5. Υφή 6. Όγκοι.....</i>	33
<i>Εικόνα 6 Εξαγωγή χαρακτηριστικών με ιστόγραμμα προσανατολισμένων κλίσεων σε μονόχρωμη εικόνα.</i>	36
<i>Εικόνα 7 : Το ορατό φάσμα φωτός.</i>	40
<i>Εικόνα 8:Decision Tree flow chart.....</i>	53
<i>Εικόνα 9: οπτικοποίηση λειτουργίας SVM.....</i>	55
<i>Εικόνα 10: οπτικοποίηση λειτουργίας KNN.</i>	56
<i>Εικόνα 11: Γραφικές παραστάσεις συναρτήσεων ενεργοποίησης.....</i>	62
<i>Εικόνα 12 : Γραφικές παραστάσεις συναρτήσεων ενεργοποίησης.....</i>	63
<i>Εικόνα 13: Παράδειγμα συνδυαστικής μεθόδου[30].....</i>	66
<i>Εικόνα 14: Παράδειγμα συνδυαστικής μεθόδου (2) [31].....</i>	67
<i>Εικόνα 15 : Παράδειγμα περιοχής 24 όνομα ασθενή: 24726, Τετραγωνάκι: patch 24, Ετικέτα: 0.....</i>	70
<i>Εικόνα 16 : Παράδειγμα περιοχής 4 όνομα ασθενή: 24726, Τετραγωνάκι: patch 4, Ετικέτα: 0</i>	71
<i>Εικόνα 17 : Διάγραμμα ροής συνδυαστικής μεθόδου.....</i>	75
<i>Εικόνα 18: Προβλέψεις Random Forest και Xgboost.....</i>	78
<i>Εικόνα 19: Αποτελέσματα παραδοσιακών αλγορίθμων μηχανικής μάθησης</i>	78
<i>Εικόνα 20 Random Forest σημαντικότητα χαρακτηριστικών</i>	79
<i>Εικόνα 21 : Xgboost σημαντικότητα χαρακτηριστικών.....</i>	79
<i>Εικόνα 22: Αποτελέσματα μόνο με feature importance.....</i>	81
<i>Εικόνα 23:Αποτελέσματα μονο με feature importance.....</i>	82
<i>Εικόνα 24: Γράφημα Συνολικων αποτελεσματων βασικων αλθοροισμων μηχανικης μαθησας</i>	82
<i>Εικόνα 25:Αποτελέσματα μοντέλου EfficientNet</i>	84
<i>Εικόνα 26: Αποτελέσματα μοντέλου EfficientNet</i>	84
<i>Εικόνα 27: Αποτελέσματα μοντέλου ResNet</i>	85
<i>Εικόνα 28: Αποτελέσματα μοντέλου ResNet</i>	86
<i>Εικόνα 29: Αποτελέσματα μοντέλου MobileNet</i>	87
<i>Εικόνα 30: Αποτελέσματα μοντέλου MobileNet</i>	88
<i>Εικόνα 31: Αποτελέσματα συνδυαστικής μεθόδου.....</i>	89
<i>Εικόνα 32: Αποτελέσματα συνδυαστικής μεθόδου.....</i>	89
<i>Εικόνα 33: Διάγραμμα feature Importance στην συνδυαστική μέθοδ</i>	90
<i>Εικόνα 34: Τελικά αποτελέσματα συνδυαστικής μεθόδου</i>	91
<i>Εικόνα 35:Τελικά αποτελέσματα συνδυαστικής μεθόδου</i>	92
<i>Εικόνα 36: Παράδειγμα επιρροής γειτονικότητας</i>	94
<i>Εικόνα 37: Παράδειγμα υποκειμενικότητας κριτή.....</i>	95

Πίνακας 1: Πίνακας ουσιών εμπλάστρου	29
Πίνακας 2: Πίνακας ετικετών ύπαρξης και έντασης δερματίτιδας.....	30
Πίνακας 3: Πίνακας metadata	30
Πίνακας 4: Πίνακας των πεδίων των metadata	31
Πίνακας 5: Confusion matrix παράδειγμα	71
Πίνακας 6: Random Forest σημαντικότητα χαρακτηριστικών.....	80
Πίνακας 7: Xgboost σημαντικότητα χαρακτηριστικών	81
Πίνακας 8: Σημαντικά χαρακτηριστικά για τον συνδυασμό μεθόδων	91
Πίνακας 9: Σημαντικά χαρακτηριστικά σε όλες τις πειραματικές διαδικασίες	92
Πίνακας 10: Ετικέτες δειγμάτων ασθενή 24625	94

Κεφάλαιο 1. Δερματίτιδα και Μηχανική Μάθηση

1.1 Εισαγωγή

Το δέρμα αποτελεί το μεγαλύτερο όργανο του ανθρώπινου σώματος καθώς καλύπτει κατά μέσο όρο 2 τετραγωνικά μέτρα στους ενήλικες. Κατά την ιστορία, το δέρμα έχει θεωρηθεί ως σύμβολο ομορφιάς και υγείας, με πολλούς αρχαίους πολιτισμούς να αναγνωρίζουν τη σημασία της φροντίδας του δέρματος τόσο για αισθητικούς όσο και για ιατρικούς σκοπούς. Στην αρχαία Αίγυπτο, για παράδειγμα, η περιποίηση του δέρματος θεωρούνταν ένα μέσο διατήρησης της νεανικότητας και προώθησης της συνολικής ευεξίας. Ομοίως, η παραδοσιακή κινεζική ιατρική έχει από καιρό αναγνωρίσει το δέρμα ως αντανάκλαση της εσωτερικής υγείας του σώματος, με θεραπείες που στοχεύουν στην αποκατάσταση της ισορροπίας και της ζωτικότητας σε αυτό¹.

Το δέρμα έχει αρκετά κρίσιμο ρόλο στο ανθρώπινο σώμα. Λειτουργεί ως φράγμα, προστατεύοντας τα εσωτερικά όργανα και τους ιστούς από εξωτερικές βλάβες, όπως η επιβλαβής ακτινοβολία UV και οι λοιμώξεις. Βοηθά επίσης στη ρύθμιση της θερμοκρασίας του σώματος, με τους ιδρωτοποιούς αδένες και τα αιμοφόρα αγγεία να συνεργάζονται για να δροσίσουν ή να ζεστάνουν το σώμα όπως χρειάζεται. Επιπλέον, το δέρμα εμπλέκεται στην αισθητηριακή αντίληψη, επιτρέποντάς μας να νιώθουμε αισθήσεις όπως το άγγιγμα, η πίεση και η θερμοκρασία.

Παρόλο που το δέρμα είναι ένα σημαντικά αξιόλογο όργανο για το ανθρώπινο σώμα, είναι επίσης ευαίσθητο σε μια ποικιλία ασθενειών και καταστάσεων που μπορεί να έχουν σοβαρές επιπτώσεις στην υγεία και την ευημερία μας. Οι δερματικές παθήσεις μπορεί να ποικίλλουν από ήπιους ερεθισμούς, όπως ακμή και έκζεμα, έως απειλητικές για τη ζωή καταστάσεις, όπως το μελάνωμα και άλλες μορφές καρκίνου του δέρματος. Ως εκ τούτου, η φροντίδα του δέρματος μας είναι εξαιρετικά σημαντική και οι τακτικοί έλεγχοι του δέρματος από το ανάλογο εξειδικευμένους ιατρούς είναι ζωτικής σημασίας για την πρόληψη και την έγκαιρη ανίχνευση δερματικών παθήσεων.

1.2 Δερματίτιδα

Η δερματίτιδα, γνωστή και ως έκζεμα, είναι μια κοινή δερματική πάθηση που επηρεάζει εκατομμύρια ανθρώπους παγκοσμίως. Κύρια χαρακτηριστικά της αποτελούν η ερυθρότητα, ο κνησμός και η φλεγμονή του δέρματος. Μπορεί να προκληθεί από διάφορους παράγοντες, όπως γενετικοί, περιβαλλοντικοί και δυσλειτουργία του ανοσοποιητικού συστήματος. Συνήθεις παράγοντες που προκαλούν την ανάπτυξη δερματίτιδας στο ανθρώπινο σώμα, περιλαμβάνουν την έκθεση σε ερεθιστικές ουσίες όπως σαπούνια, απορρυπαντικά και ορισμένα μέταλλα, καθώς και αλλεργιογόνες ουσίες όπως γύρη και τρίχωμα ζώων. Επιπλέον σε ορισμένες περιπτώσεις και εξωγενείς αιτίες όπως το άγχος, το κλίμα και ο τρόπος ζωής μπορούν αποτελέσουν καθοριστικό παράγοντα και να συμβάλουν στην ανάπτυξη δερματίτιδας.

¹ <https://en.wikipedia.org>

Τα συμπτώματα της δερματίτιδας ποικίλλουν ανάλογα με τον τύπο και τη σοβαρότητα της πάθησης, με τα συχνότερα από αυτά να περιλαμβάνουν ερυθρότητα, κνησμό, ξηρότητα, απολέπιση και σχηματισμό κρούστας του δέρματος. Σε ορισμένες περιπτώσεις, μπορεί επίσης να εμφανιστούν φουσκάλες και διαρροή. Η θέση και η εμφάνιση της δερματίτιδας μπορεί επίσης να ποικίλλει, με ορισμένους τύπους να επηρεάζουν συγκεκριμένες περιοχές του σώματος όπως τα χέρια, το πρόσωπο ή το κεφάλι. Η έλλειψη έγκαιρης πρόληψης και θεραπείας μπορεί να οδηγήσει σε επιπλοκές όπως μόλυνση, ουλές και αλλαγές στο χρώμα ή την υφή του δέρματος και να αποτελέσει μια εξαιρετικά ζημιογόνα για τον οργανισμό ασθένεια [1].

1.3 Τύποι Δερματίτιδας

Λόγω της ευρείας γκάμας τόσο σε συμπτώματα όσο και σε αιτίες η επιστημονική κοινότητα κατηγοριοποιεί την δερματίτιδα σε διάφορους τύπους. Κάποιοι από τους συνηθέστερους τύπους δερματίτιδας που επηρεάζουν μεγάλα ποσοστά του πληθυσμού αναφέρονται παρακάτω.

Κυριότερη μορφή αποτελεί η ατοπική δερματίτιδα (Atopic Dermatitis) γνωστή και ως έκζεμα, που είναι μια χρόνια πάθηση του δέρματος που χαρακτηρίζεται από ξηρό δέρμα, κνησμό και φλεγμονή. Η ακριβής αιτία της ατοπικής δερματίτιδας είναι άγνωστη, αλλά πιστεύεται ότι σχετίζεται με υπερδραστήρια ανοσοαπόκριση σε παράγοντες όπως αλλεργιογόνα ή ερεθιστικά. Η πάθηση μπορεί να εμφανιστεί σε οποιαδήποτε ηλικία, αλλά είναι πιο συχνή σε βρέφη και παιδιά. Οι συνήθεις παράγοντες που προκαλούν την ατοπική δερματίτιδα περιλαμβάνουν την έκθεση σε σκληρά σαπούνια, απορρυπαντικά και υφάσματα, καθώς και αλλαγές στη θερμοκρασία και την υγρασία. Εκτός από τη σωματική δυσφορία, η ατοπική δερματίτιδα μπορεί να έχει σημαντικό αντίκτυπο στην ποιότητα ζωής ενός ατόμου, επηρεάζοντας τον ύπνο, την αυτοεκτίμηση και τη συνολική ευεξία. Αν και δεν υπάρχει θεραπεία για την ατοπική δερματίτιδα, υπάρχουν αρκετές διαθέσιμες θεραπευτικές επιλογές για τη διαχείριση των συμπτωμάτων, όπως ενυδατικές κρέμες, τοπικά κορτικοστεροειδή και ανοσοκατασταλτικά φάρμακα [2].

Η δερματίτιδα εξ επαφής (Contact Dermatitis) είναι ένας τύπος δερματίτιδας που προκαλείται από την έκθεση σε μια ουσία που ερεθίζει το δέρμα ή προκαλεί αλλεργική αντίδραση. Η κατάσταση μπορεί να εκδηλωθεί ως εξάνθημα, φουσκάλες ή ξηρό, φολιδωτό δέρμα. Οι συνήθεις αιτίες της δερματίτιδας εξ επαφής περιλαμβάνουν την έκθεση σε φυτά, όπως ο δηλητηριώδης κισσός ή η βελανιδιά, καθώς και η έκθεση σε χημικές ουσίες, όπως αυτές που βρίσκονται σε προϊόντα καθαρισμού ή καλλυντικά. Η πάθηση μπορεί να επηρεάσει άτομα όλων των ηλικιών και μπορεί να είναι οξεία ή χρόνια [3].

Επιπλέον υπάρχει η σημηματορροϊκή δερματίτιδα (Seborrheic Dermatitis), που αποτελεί μια κοινή δερματική πάθηση που συνήθως επηρεάζει το τριχωτό της κεφαλής, προκαλώντας φολιδωτές και κόκκινες κηλίδες. Ωστόσο, μπορεί επίσης να εμφανιστεί και σε άλλα μέρη του σώματος, όπως το πρόσωπο, τα αυτιά και το στήθος. Η κατάσταση μπορεί να προκληθεί από διάφορους παράγοντες, συμπεριλαμβανομένων των ορμονικών αλλαγών, του στρες και της γενετικής. Στα βρέφη, είναι κοινώς γνωστό ως κάλυμμα κούνιας και συνήθως υποχωρεί από μόνο του μέσα σε λίγους μήνες [4].

Η αριθμητική δερματίτιδα (Nummular dermatitis) είναι ένας τύπος δερματίτιδας που χαρακτηρίζεται από κηλίδες ερεθισμένου δέρματος σε σχήμα νομίσματος. Η ακριβής αιτία της πάθησης είναι άγνωστη, αλλά πιστεύεται ότι προκαλείται από έναν συνδυασμό γενετικών και περιβαλλοντικών παραγόντων. Κυρία συμπτώματα αποτελούν η φαγούρα και το ξηρό δέρμα, αλλά και η γενικότερη έκθεση σε ερεθιστικούς παράγοντες και τις αλλεργίες. Η αριθμητική δερματίτιδα είναι πιο συχνή σε μεσήλικες και ηλικιωμένους και είναι πιο διαδεδομένη στους άνδρες παρά στις γυναίκες [5].

Το δυσιδρωτικό έκζεμα, (Dyshidrosis Dermatitis) είναι ένας τύπος δερματίτιδας που συνήθως προσβάλλει τα χέρια και τα πόδια και χαρακτηρίζεται από μικρές, κνησμώδεις φουσκάλες. Η κατάσταση μπορεί να προκληθεί από το στρες, την έκθεση σε ορισμένες ουσίες όπως το νικέλιο ή το κοβάλτιο ή την έκθεση σε υγρές συνθήκες. Η ακριβής αιτία της πάθησης είναι άγνωστη, αλλά πιστεύεται ότι σχετίζεται με υπερδραστήρια ανοσοαπόκριση. Οι φουσκάλες μπορεί να είναι επώδυνες και μπορεί να οδηγήσουν σε σκάσιμο και απολέπιση του δέρματος [6].

Περιστοματική δερματίτιδα (Perioral dermatitis), είναι ο τύπος δερματίτιδας κατά τον οποίο εμφανίζεται ένα εξάνθημα στο πρόσωπο γύρω από το στόμα, τη μύτη ή τα μάτια. Χαρακτηρίζεται από μικρά κόκκινα εξογκώματα, φλύκταινες ή βλατίδες που μπορεί να προκαλούν φαγούρα και μερικές φορές να είναι επώδυνες. Εμφανίζεται συνήθως σε γυναίκες και μπορεί να προκληθεί από τη χρήση τοπικών στεροειδών, καλλυντικών ή οδοντόκρεμας με φθόριο. Η θεραπεία μπορεί να περιλαμβάνει την χρήση τοπικών αντιβιοτικών και άλλων μεθοδων [7].

Τέλος, η δερματίτιδα στάσεως (Stasis dermatitis), τύπος δερματίτιδας που αποτελεί δερματική πάθηση που εμφανίζεται στα κάτω πόδια λόγω κακής κυκλοφορίας. Χαρακτηρίζεται από οίδημα, ερυθρότητα και κνησμό της πληγείσας περιοχής. Πιθανή αιτία πρόκλησης προκληθεί από υποκείμενες παθήσεις όπως η φλεβική ανεπάρκεια ή η καρδιακή ανεπάρκεια[8].

Όπως βλέπουμε και παραπάνω η ύπαρξη πολλών τύπων και η διαφοροποίηση των συμπτωμάτων καθώς και το γεγονός ότι συναντάται σε μεγάλο κομμάτι του πληθυσμού, καθιστούν την δερματίτιδα μια ασθένεια με ευρύ φάσμα, και καθιστά τόσο την θεραπεία της όσο και την ανίχνευση της σε αρχικά στάδια ζήτημα καίριας σημασίας.

1.4 Ανίχνευση

Για την ανίχνευση της δερματίτιδας, οι γιατροί πραγματοποιούν συνήθως μια φυσική εξέταση της ερεθισμένης περιοχής και ρωτούν τον ασθενή για το ιατρικό ιστορικό του και οποιαδήποτε έκθεση σε ερεθιστικά ή αλλεργιογόνα. Μερικές φορές, οι γιατροί μπορεί να χρησιμοποιήσουν ένα δοκιμαστικό επίθεμα (patch test) για να προσδιορίσουν την αιτία της δερματίτιδας. Η διαδικασία περιλαμβάνει την εφαρμογή μικρών ποσοτήτων διαφορετικών ουσιών, όπως αρώματα ή μέταλλα, στο δέρμα του ασθενούς και την κάλυψη τους με ένα έμπλαστρο για μερικές ημέρες. Εάν ο ασθενής εμφανίσει εξάνθημα ή φλεγμονή, μπορεί να υποδηλώνει αλλεργική αντίδραση σε μία από τις ουσίες που δοκιμάστηκαν.

Το έμπλαστρο είναι ένα κοινό διαγνωστικό εργαλείο για την αλλεργική δερματίτιδα εξ επαφής. Κατά τη διάρκεια της δοκιμής με επίθεμα, πολλά μικρά έμπλαστρα που περιέχουν

διαφορετικές ουσίες τοποθετούνται στην πλάτη του ασθενούς και αφήνονται για μερικές ημέρες. Αφού αφαιρεθούν τα έμπλαστρα, ο δερματολόγος θα εξετάσει το δέρμα για να διαπιστώσει εάν έχει εμφανιστεί κάποια αντίδραση. Το τεστ μπορεί να βοηθήσει στον εντοπισμό των ουσιών που προκαλούν τη δερματίτιδα και τα αποτελέσματα μπορούν να καθοδηγήσουν τον ασθενή στην αποφυγή αυτών των ερεθισμάτων στο μέλλον. Το έμπλαστρο είναι γενικά ασφαλές, αλλά υπάρχει κίνδυνος ανάπτυξης σοβαρής αλλεργικής αντίδρασης σε σπάνιες περιπτώσεις [9].

Το πιο συχνά χρησιμοποιούμενο έμπλαστρο είναι η σειρά North American Contact Dermatitis Group (NACDG), η οποία περιλαμβάνει ένα τυπικό σύνολο 80 έως 90 αλλεργιογόνων που αποτελούν κοινές αιτίες δερματίτιδας εξ επαφής, κάποιες από τις οποίες φαίνονται στην Εικόνα 1 και 2 [10]. Άλλα έμπλαστρα μπορεί να περιλαμβάνουν πρόσθετες ουσίες που είναι συγκεκριμένες για το επάγγελμα ή τα χόμπι του ασθενούς. Το patch test δεν είναι κατάλληλο για όλες τις περιπτώσεις δερματίτιδας, καθώς χρησιμοποιείται κυρίως για τον εντοπισμό αλλεργιογόνων που προκαλούν αλλεργική δερματίτιδα εξ επαφής. Άλλες μορφές δερματίτιδας μπορεί να απαιτούν διαφορετικές διαγνωστικές μεθόδους[9].

No.	Test substance*	No. (1994–1996)	Percent allergic (1994–1996)	Definite relevance (%)	Probable relevance (%)	Possible relevance (%)	Past relevance (%)
1.	Benzocaine 5%	3112	2.6	9.9	11.1	20	33
2.	Mercaptobenzothiazole 1%	3115	2.1	16.9	35.4	27	7.7
3.	Colophony 20%	3113	2.6	9.9	7.4	33	12
4.	p-phenylenediamine 1%	3111	6.8	6.7	21	20	14
5.	Imidazolidinyl urea 2% aqueous	3101	2.6	14.6	30.5	34	3.7
6.	Cinnamic aldehyde 1%	3112	2.4	5.3	27.6	53	2.6
7.	Wool wax alcohol 30%	3114	3.3	16.7	32.4	34	4.9
8.	Carba mix 3%	3115	5.7	15.9	24.4	32	7.4
9.	Neomycin 20%	3104	11.6	11.1	20.2	10	36
10.	Thiuram mix 1%	3115	6.8	18.4	36.3	28	6.1
11.	Formaldehyde 1% aqueous	3111	9.2	10.1	22.7	42	4.2
12.	Ethylenediamine DHCl 1%	3113	2.9	2.2	5.6	14	22
13.	Epoxy resin 1%	3114	2.2	16.4	23.9	22	3
14.	Quaternium-15 2%	3110	9.2	18.2	40.2	27	5.6
15.	p-tert-butylphenol formaldehyde resin 1%	3114	2.7	10.6	16.5	31	4.7
16.	Mercapto mix 1%	3115	2.2	17.4	27.5	38	5
17.	Black rubber mix 0.6%	3113	2.3	7	11.3	39	7
18.	Potassium dichromate 0.25%	3106	2.0	8.1	27.4	24	15
19.	Balsam of Peru 25%	3112	10.4	5.8	19.4	50	6.2
20.	Nickel sulphate 2.5%	3108	14.3	5.6	18.2	21	40

*Allergens in petrolatum unless noted aqueous.

†Calculated with χ^2 with Yates' correction; no adjustment for age, sex, location, or test center.

Εικόνα 1: Αντίδραση του δέρματος στις ουσίες του NACDG από 1 έως 20 [10]

No.	Test substance*	No. (1994–1996)	Percent allergic (1994–1996)	Definite relevance (%)	Probable relevance (%)
21.	Diazolidinyl urea 1%	3085	3.7	9.6	38.3
22.	DMDM hydantoin 1%	3082	2.3	12.5	36.1
23.	Imidazolidinyl urea 2%	3080	3.1	10.3	35.1
24.	Bacitracin 20%	3079	9.1	12.5	27.4
25.	Mixed dialkyl thiourea 1%	3075	0.7	27.3	22.7
26.	Methylchloroisothiazolinone/ methylisothiazolinone 100 ppm aqueous	3075	3.0	20.7	45.7
27.	Paraben mix 15%	3086	1.8	5.7	43.4
28.	Methyldibromo glutaronitrile/ phenoxyethanol 1%	3074	2.0	5	10
29.	Fragrance mix 8%	3082	14.0	8.6	35.5
30.	2-bromo-2-nitropropane 0.5%	3074	2.3	2.8	14.1
31.	Thimerosal 0.1%	3075	10.4	2.2	3.8
32.	Propylene glycol 10%	3077	1.1	14.3	25.7
33.	Methylchloroisothiazolinone/ methylisothiazolinone 100 ppm, pet	3078	3.0	18.5	47.8
34.	Chloroxylenol 1%	3074	1.2	8.1	32.4
35.	DMDM hydantoin 1%, aqueous	3064	2.1	10.8	33.8
36.	Diazolidinyl urea 1%, aqueous	3060	3.7	8	35.7
37.	Phenoxyethanol 1%	3080	0	0	0
38.	Cobalt chloride 1%	3087	8.0	4.1	12.2
39.	Sesquiterpene lactone mix 0.1%	3073	0.9	10.7	28.6
40.	Budesonide 0.1%	1678	1.1	33.3	22.2
41.	Tixocortol pivalate 1%	3091	2.3	8.5	46.5
42.	BHA 2%	3076	0.5	6.7	0
43.	Glutaraldehyde 0.2%	3076	0.7	30.4	26.1
44.	Glutaraldehyde 1.0%	3075	2.2	20.9	22.4
45.	BHT 2%	3076	0.2	0	14.3
46.	Ethyl acrylate 0.1%	3074	1.8	18.5	29.6
47.	Glyceryl thioglycolate 1%	3075	5	8.1	27.4
48.	Toluene sulfonamide resin 10%	3077	1.6	14.6	33.3
49.	Methyl-methacrylate 2%	3080	1.2	16.7	36.1
50.	Ethyleneurea melamine-formaldehyde 5%	3071	5.0	7.7	19.4

NA, Not applicable; NC, Not calculated; NT, not tested.

*Allergens in petrolatum unless noted aqueous.

†Calculated with χ^2 with Yate's correction; no adjustment for age, sex, location, or test center.

‡Calculated with Fisher's exact test two-tailed.

Εικόνα 2: Αντίδραση του δέρματος στις ουσίες του NACDG από 21 έως 50 [10]

Εκτός από το έμπλαστρο, οι γιατροί μπορούν να χρησιμοποιήσουν άλλες μεθόδους για τη διάγνωση της δερματίτιδας, όπως εξετάσεις αίματος για την ανίχνευση συγκεκριμένων αντισωμάτων ή βιοψίες δέρματος για την εξέταση του προσβεβλημένου ιστού δέρματος. Τελικά, μια ακριβής διάγνωση είναι κρίσιμη για την αποτελεσματική αντιμετώπιση της δερματίτιδας και οι ασθενείς θα πρέπει να αναζητήσουν ιατρική βοήθεια εάν εμφανίσουν επίμονα ή σοβαρά συμπτώματα.

1.5 Πρόληψη και θεραπεία

Λόγω την μεγάλης ποικιλομορφίας δεν υπάρχει γνωστή και ενιαία θεραπεία για τη δερματίτιδα, ωστόσο υπάρχουν πολλά προληπτικά μέτρα και θεραπείες που μπορούν να βοηθήσουν στην ανακούφιση των συμπτωμάτων και στην πρόληψη των εξάρσεων.

Η πρόληψη είναι το κλειδί όταν πρόκειται για τη διαχείριση της δερματίτιδας. Ένα από τα πιο σημαντικά προληπτικά μέτρα είναι η αποφυγή πυροδοτήσεων που μπορούν να προκαλέσουν εξάρσεις. Για παράδειγμα, εάν η δερματίτιδα εξ επαφής προκαλεί ανησυχία, η

αποφυγή επαφής με γνωστά ερεθιστικά, όπως ορισμένες χημικές ουσίες ή μέταλλα, μπορεί να βοηθήσει στην πρόληψη των συμπτωμάτων. Για όσους πάσχουν από έκζεμα, είναι σημαντικό να διατηρούν το δέρμα τους ενυδατωμένο και να αποφεύγουν παράγοντες όπως το άγχος καθώς και ορισμένες τροφές.

Εκτός από την πρόληψη, υπάρχουν διάφορες επιλογές θεραπείας διαθέσιμες για όσους έχουν δερματίτιδα. Μία από τις πιο κοινές θεραπείες είναι η χρήση τοπικών κορτικοστεροειδών. Αυτά είναι αντιφλεγμονώδη φάρμακα που μπορούν να βοηθήσουν στη μείωση του κνησμού και της φλεγμονής. Σε ορισμένες περιπτώσεις, από του στόματος αντιισταμινικά ή ανοσοκατασταλτικά φάρμακα μπορεί επίσης να συνταγογραφηθούν για τη διαχείριση των συμπτωμάτων.

Μια άλλη θεραπευτική επιλογή για τη δερματίτιδα είναι η φωτοθεραπεία, η οποία περιλαμβάνει την έκθεση του δέρματος σε συγκεκριμένα μήκη κύματος φωτός. Αυτό μπορεί να βοηθήσει στη μείωση της φλεγμονής και στην προώθηση της επούλωσης. Σε ορισμένες περιπτώσεις, συστηματικά φάρμακα όπως βιολογικά ή ανοσοτροποποιητικά μπορεί επίσης να χρησιμοποιηθούν για τη διαχείριση σοβαρών περιπτώσεων δερματίτιδας.

Εκτός από αυτές τις επιλογές θεραπείας, υπάρχουν επίσης αρκετές αλλαγές στον τρόπο ζωής που μπορούν να βοηθήσουν στη διαχείριση των συμπτωμάτων της δερματίτιδας. Αυτές περιλαμβάνουν τη διατήρηση μιας υγιεινής διατροφής, την αποφυγή του στρες και την άσκηση καλής υγιεινής του δέρματος. Για παράδειγμα, το σύντομο, χλιαρό ντους και η αποφυγή σκληρών σαπουνιών και σαμπουάν μπορεί να βοηθήσει στην πρόληψη της ξηροδερμίας και στη μείωση του κινδύνου εξάρσεων.

Συνολικά, ενώ δεν υπάρχει γνωστή θεραπεία για τη δερματίτιδα, υπάρχουν πολλές διαθέσιμες αποτελεσματικές επιλογές πρόληψης και θεραπείας. Με τη στενή συνεργασία με έναν πάροχο υγειονομικής περίθαλψης και τη λήψη μέτρων για την πρόληψη των εξάρσεων, τα άτομα με δερματίτιδα μπορούν να διαχειριστούν με επιτυχία τα συμπτώματά τους και να απολαύσουν καλύτερη ποιότητα ζωής [11].

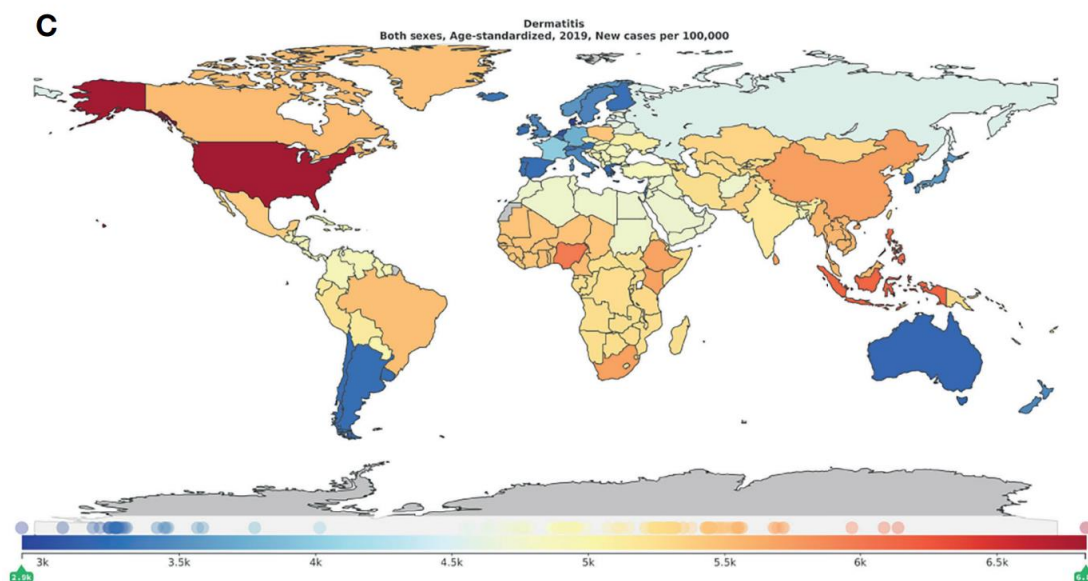
1.6 Επιπολασμός δερματίτιδας

Σύμφωνα με πρόσφατες μελέτες, η δερματίτιδα είναι μια σημαντική ανησυχία για τη δημόσια υγεία που επηρεάζει εκατομμύρια ανθρώπους σε όλο τον κόσμο. Μια πρόσφατη μελέτη έδειξε ότι η επιβάρυνση από δερματίτιδα (AD, CD, SD) αντιπροσώπευε το 0,38% του συνόλου ασθενειών που προκαλούνται από όγκους του δέρματος, συμπεριλαμβανομένου 0,06% για κακοήγη μελάνωμα δέρματος και 0,03% για καρκίνωμα κερατινοκυττάρων.[12].

Γενικότερα η δερματίτιδα αποτελεί σημαντικό παγκόσμιο πρόβλημα δημόσιας υγείας καθώς επηρεάζει το 1%-20% του παγκοσμίου πληθυσμού [11]. Πιο συγκεκριμένα, σύμφωνα με την μελέτη της Rebecca Berke η ατοπική δερματίτιδα επηρεάζει στις ΗΠΑ σχεδόν 17.8 εκατομμύρια ανθρώπους[2]. Ωστόσο η εξάπλωση της συναντιέται και σε ευρωπαϊκές χώρες, με πρώτες δυο την Βουλγαρία και την Εσθονία να εμφανίζουν πόστα άνω του 15% του συνολικού πληθυσμού [13] . Η δερματίτιδα επηρεάζει άτομα όλων των ηλικιών, με την πάθηση να είναι πιο συχνή σε παιδιά και νεαρούς ενήλικες. Η ατοπική δερματίτιδα, για παράδειγμα, είναι μια κοινή παιδική πάθηση που επηρεάζει το 1%-3% των ενήλικων αλλά το 10%-20% των παιδιών και των εφήβων παγκοσμίως [11].

Στους ενήλικες, η δερματίτιδα εξ επαφής είναι η πιο κοινή μορφή πάθησης, που εκτιμάται ότι συναντάται σε 5.7 εκατομμύρια ασθενείς κάθε χρόνο με την κύρια υποκατηγορία της την δερματίτιδα στα χέρια που απασχολεί το 2-6% του παραπάνω πληθυσμού². Ωστόσο εμφανίζεται και στα παιδιά, με μελέτες να δείχνουν ότι απασχολεί 4.4 εκατομμύρια παιδιά το χρόνο [14]. Τέλος ακόμα και η σπανιότερη σμηγματορροϊκή δερματίτιδα αποτελεί μια σχετικά κοινή πάθηση που απασχολεί 10 εκατομμύρια ανθρώπους παγκοσμίως με την κυριότερη εστία της να βρίσκεται στις ΗΠΑ [14].

Παρακάτω στην Εικόνα 3 συναντάται ένας χάρτης όπου υποδεικνύει την εξάπλωση της δερματίτιδας στον παγκόσμιο χάρτη σύμφωνα με το GDB2019 [14].



Εικόνα 3: Χάρτης εξάπλωσης δερματίτιδας[14]

1.7 State of the art in ML

Δεδομένου του υψηλού επιπολασμού της δερματίτιδας παγκοσμίως, υπάρχει σημαντική ανάγκη για αποτελεσματικές μεθόδους διάγνωσης και θεραπείας. Επί του παρόντος, η δερματίτιδα διαγιγνώσκεται κυρίως με βάση την κλινική αξιολόγηση και το ιστορικό του ασθενούς, κάτι που μπορεί να είναι χρονοβόρο και δαπανηρό. Σε αυτό το σημείο, οι αλγόριθμοι μηχανικής μάθησης μπορούν να παίξουν κρίσιμο ρόλο. Αξιοποιώντας μεγάλα σύνολα δεδομένων πληροφοριών ασθενών, οι αλγόριθμοι μηχανικής μάθησης μπορούν να εντοπίσουν μοτίβα και να προβλέψουν τα αποτελέσματα, παρέχοντας μια πιο αποτελεσματική και ακριβή μέθοδο διάγνωσης και θεραπείας της δερματίτιδας

Το ζήτημα της ανίχνευσης της δερματίτιδας από εικόνες με χρήση μηχανικής μάθησης έχει απασχολήσει σε μεγάλο βαθμό την επιστημονική κοινότητα με πολλά πανεπιστήμια και ερευνητικές ομάδες να αξιοποιούν ερευνητικούς πόρους για την βελτίωση και την επίτευξη του παραπάνω σκοπού. Κυρίο μέλημα είναι η συλλογή όγκου δεδομένων από ασθενείς αλλά και η μελέτη και οι δοκιμές με διάφορα μοντέλα μηχανικής μάθησης με τελικό σκοπό την

² <https://www.worldallergy.org>

επίτευξη της καλύτερης δυνατής ακρίβειας κατά την πρόβλεψη [15]–[17]. Μερικές από τις πιο πρωτοποριακές μελέτες που έχουν γίνει αναφέρονται παρακάτω.

Τα συνελκτικά νευρωνικά δίκτυα (CNN) είναι ο πιο ευρέως χρησιμοποιούμενος τύπος νευρωνικών δικτύων για εργασίες ταξινόμησης εικόνων στη δερματολογία. Τα CNN είναι ιδιαίτερα κατάλληλα για ανάλυση εικόνων, επειδή μπορούν να αναγνωρίσουν μοτίβα και χαρακτηριστικά σε εικόνες που δεν είναι ορατά με το ανθρώπινο μάτι.

Μία από τις πιο σημαντικές εξελίξεις στη δερματολογία με τη χρήση μηχανικής μάθησης ήταν η ανάπτυξη αλγορίθμων βαθιάς μάθησης. Οι αλγόριθμοι βαθιάς μάθησης χρησιμοποιούν πολλαπλά επίπεδα νευρωνικών δικτύων για την εξαγωγή χαρακτηριστικών από εικόνες. Αυτοί οι αλγόριθμοι έχουν αποδειχθεί ότι ξεπερνούν τους παραδοσιακούς αλγόριθμους μηχανικής μάθησης σε εργασίες ταξινόμησης εικόνων, συμπεριλαμβανομένης της ανίχνευσης δερματίτιδας. Εκτός από τα CNN και τους αλγόριθμους βαθιάς μάθησης, άλλες τεχνικές μηχανικής μάθησης, όπως δέντρα αποφάσεων και μηχανές υποστήριξης διανυσμάτων έχουν επίσης χρησιμοποιηθεί για την ανίχνευση δερματίτιδας.

Έχουν διεξαχθεί αρκετές μελέτες για την αξιολόγηση της απόδοσης των αλγορίθμων μηχανικής μάθησης στην ανίχνευση δερματίτιδας από εικόνες. Σε μια μελέτη που διεξήχθη από τους Andre Esteva και Brett Kurland Esteva αναπτύχθηκε και εκπαιδεύτηκε ένας αλγόριθμος βαθιάς μάθησης σε ένα σύνολο δεδομένων με σχεδόν από 130.000 κλινικές εικόνες 2,032 διαφορετικών δερματικών παθήσεων, συμπεριλαμβανομένης της δερματίτιδας. Ο αλγόριθμος πέτυχε ακρίβεια ταξινόμησης 91% σε ένα σύνολο εικόνων επικύρωσης, η οποία ήταν υψηλότερη από την ακρίβεια που πέτυχε μια ομάδα 21 πιστοποιημένων δερματολόγων [16].

Μια άλλη μελέτη που διεξήχθη από τους Tschandl et al. συνέκρινε την απόδοση τριών διαφορετικών αλγορίθμων βαθιάς μάθησης στην ανίχνευση δερματίτιδας. Οι αλγόριθμοι εκπαιδεύτηκαν σε ένα σύνολο δεδομένων με περισσότερες από 10.000 εικόνες πετυχαίνοντας ποσοστά της τάξης του 88% αλλά και δημιουργώντας ένα πολύ χρήσιμο και μεγάλο dataset το HAM10000 dataset. Τα αποτελέσματα της μελέτης έδειξαν ότι οι αλγόριθμοι μηχανικής μάθησης πέτυχαν συγκρίσιμη ακρίβεια με τους ανθρώπινους αναγνώστες στην ταξινόμηση των μελαγχρωματικών βλαβών του δέρματος. Στην πραγματικότητα, οι αλγόριθμοι με την καλύτερη απόδοση ξεπέρασαν ακόμη και ένα μεγάλο ποσοστό των ειδικών. Αυτό το εύρημα υπογραμμίζει τις δυνατότητες των αλγορίθμων μηχανικής μάθησης ως πολύτιμα εργαλεία στη δερματολογική πρακτική [17].

Τέλος πιο κοντά και στην δική μας προσέγγιση οι M. Abo-Tabik και R. Parisi εστίασαν στην εφαρμογή τεχνικών μηχανικής μάθησης για την αυτοματοποιημένη ανίχνευση δερματικών αντιδράσεων σε δοκιμές επιδερμικών επιθεμάτων. Η συγκεκριμένη μελέτη έγινε σε ένα σύνολο 3695 εικόνων δερματίτιδας (118 θετικές, 3577 αρνητικές) και κατάφερε να πετύχει F1 score τη τάξης το 0.89 [15].

Κεφάλαιο 2. Ασθενείς και συλλογή δεδομένων


2.1 Εισαγωγή

Στα πλαίσια έρευνας πραγματοποιήθηκε μια δειγματοληπτική διαδικασία με στόχο την ανίχνευση και διάγνωση περιπτώσεων της δερματίτιδας σε 200 πραγματικούς ασθενείς. Τα δεδομένα προήλθαν από την Α΄ Πανεπιστημιακή Κλινική Δερματολογικών και Αφροδίσιων Νοσημάτων (ΑΠΚΔΑΝ), Νοσοκομείο Α. Συγγρός, Εθνικό Καποδιστριακό Πανεπιστήμιο Αθηνών. Η διαδικασία περιλάμβανε τη πραγματοποίηση τριών διαδοχικών επισκέψεων σε δερματολόγο από τον κάθε ασθενή, κατά τις οποίες αξιολογούνταν η αντίδραση του δέρματος σε ένα ειδικό επίθεμα που είχε τοποθετηθεί αρχικά. Επιπλέον εκτός από την διάγνωση των ασθενών, λάμβανε χώρα και η λήψη φωτογραφιών των εν λόγω περιοχών χρησιμοποιώντας μια κάμερα Antera 3D. Οι εξής 6 τύποι εικόνων που αποσπάστηκαν από κάθε ασθενή ήταν Χρώμα, Λεπτές γραμμές, Διπλώσεις, Ερυθρότητα, Υφή και Όγκοι (Color, Fine Line, Folds, Redness, Texture and Volumes) και η συλλογή τους έγινε με σκοπό να συγκεντρωθεί σύνολο δεδομένων εικόνων που θα μπορούσαν να χρησιμοποιηθούν για την εκπαίδευση αλγόριθμων μηχανικής μάθησης.


2.2 Διαδικασία εξέτασης

Όπως αναφέρθηκε και στο προηγούμενο κεφάλαιο η συνηθέστερη μέθοδος εντοπισμού δερματίτιδας γίνεται με τη χρήση επιθέματος και περιλαμβάνει την εφαρμογή μικρών ποσοτήτων διαφορετικών ουσιών και αρωμάτων. Η διάγνωση γίνεται με φυσική εξέταση της πληγείσας περιοχής από εξειδικευμένο Ιατρικό προσωπικό και περιλαμβάνει την αξιολόγηση της αντίδρασης του δέρματος με τις περιοχές του επιθέματος. Η συγκεκριμένη μέθοδος εφαρμόστηκε και στην συλλογή του δικού μας συνόλου δεδομένων. Επομένως πραγματοποιήθηκαν τρεις επισκέψεις, μετά από 48 και 72 ώρες αντίστοιχα από την αρχική τοποθέτηση του επιθέματος στην περιοχή του ερεθισμού. Το επίθεμα που χρησιμοποιήθηκε για την συλλογή των δεδομένων αποτελείται από 30 περιοχές (chambers) που περιέχουν διάφορες αλλεργιογόνες και μη ουσίες όπως φαίνεται και παρακάτω στην Εικόνα 4. Στον πίνακα 1 απεικονίζονται οι ουσίες και οι αντίστοιχες περιεκτικότητες για κάθε περιοχή του επιθέματος. Σκοπός της παραπάνω διαδικασίας είναι ο έλεγχος για αλλεργική αντίδραση σε μία από τις παραπάνω ουσίες ώστε να υποδειχθεί το είδος και η ένταση της δερματίτιδας.


Antera 3D - patch test 1



Antera 3D - patch test 2



Antera 3D - patch test 3



Εικόνα 4: Χωροταξική τοποθέτηση των περιοχών του εφαρμοσμένου έμπλαστρου

ΟΥΣΙΑ			ΑΠΑΝΤΗΣΗ				ΟΥΣΙΑ			ΑΠΑΝΤΗΣΗ			
			24h	48h	72h	96h				24h	48h	72h	96h
1	Potassium Dichromate	0.5%					16	Paratertiarybutyl Phenol formaldehyde Resin(BPF-Resin)	1%				
2	Neomycin Sulphate	20%					17	Fragrance Mix I	8%				
3	Thiuram Mix	1%					18	Ethylenediamine Dihydr	1%				
4	Paraphenylenediamine	1%					19	Quaternium 15	1%				
5	Cobalt Chloride	1%					20	Nickel Sulphate	5%				
6	Caine Mix	7%					21	5-Chloro-2-methyl-4-isothiazolin- 3-one/2-Methyl-4-isothiazolin-3- one (KATHON)	0,02%				
7	Formaldehyde	2%					22	Mercaptobenzothiazole(MBT)	2 %				
8	Colophonium	20%					23	Propolis	10%				
9	2-Hydroxyethyl - Methacrylate(HEMA)	2%					24	Textile Dye Mix	6,6%				
10	Balsam of Peru	25%					25	Petrolatum Control	100%				
11	PPD-Black Rubber Mix	0,1%					26	Budesonide	0,01%				
12	Wool Alcohols	30%					27	Thiomersal	0,1%				
13	Mercapto Mix	2%					28	Methyldibromo-Glutaronitrile	0,5%				
14	Epoxy Resin	1%					29	Sesquiterpenelactone Mix	0.1%				
15	Paraben Mix	16%					30	Fragrance Mix II	14%				

Πίνακας 1: Πίνακας ουσιών εμπλάστρου

Κατά την διάρκεια της δεύτερης και της τρίτης εξέτασης το επίθεμα αφαιρείται και καταγράφεται η ένταση της αντίδρασης του δέρματος με κάθε ουσία, την οποία αξιολογεί εξειδικευμένος Ιατρός όπως φαίνεται στον παρακάτω πίνακα:

ID	1		2		3		4	
	48h	72h	48h	72h	48h	72h	48h	72h
24304								
24305								
24306								
24309								
24311								
24312					1	2		
24314								
24315								
24320								
24321		1						
24323								
24324								
24326								1

Πίνακας 2: Πίνακας ετικετών ύπαρξης και έντασης δερματίτιδας

Για κάθε ουσία (chamber) σε κάθε εξέταση παρέχεται μια τιμή από 0-3 που θα αποτελέσει την ετικέτα του κατά την διάρκεια της εκπαίδευσης των μοντέλων μηχανικής μάθησης. Οι ετικέτες αντιδρούν σε 0 - αρνητικό - καμία αντίδραση, 1 - ήπια αντίδραση, 2 - μέτρια αντίδραση και 3 - σοβαρή αντίδραση. Τέλος ο δερματολόγος παρέχει διαβαθμισμένη εκτίμηση της έντασης μόνο για τις περιοχές που περιέχεται οίδημα, με αυτές τις περιοχές να ονομάζονται περιοχές ενδιαφέροντος. Τα υπόλοιπα τετραγωνάκια που είναι κενά δεν αποτελούν περιοχές ενδιαφέροντος και δεν συμμετέχουν στην ανάλυση.

2.3 Metadata

Στην παραπάνω διαβαθμισμένη αξιολόγηση της έντασης της αντίδρασης του δέρματος, το ιατρικό προσωπικό παρέχει και ένα σύνολο επιπλέον δεδομένων κατά την διάρκεια κάθε μέτρησης. Πιο συγκεκριμένα στον πίνακα 3 περιέχονται τα εν λόγω δεδομένα μαζί, ενός τυχαίου ασθενούς, τα οποία έπειτα από επεξεργασία και διατήρηση των αριθμητικών μεταβλητών, χρησιμοποιήθηκαν συμπληρωματικά στα δεδομένα των εικόνων για την βελτιστοποίηση της πρόβλεψης των τιμών δερματίτιδας.

Image	Timestamp	Version	Selection	Channel	Color - Skin Type	Color Variation
patch 1- area 2.an-img	Δευτέρα 10 Ιανουαρίου 2022 10:02:18 πμ	3.1.2.7206	Square: Side length: 9.8 mm	Color	2	2.62
patch 1- area 2 (2).an-img	Τετάρτη 12 Ιανουαρίου 2022 9:20:26 πμ	3.1.2.7206	Square: Side length: 9.8 mm	Color	3	4.279
patch 1- area 2 (3).an-img	Πέμπτη 13 Ιανουαρίου 2022 10:16:48 πμ	3.1.2.7206	Square: Side length: 9.8 mm	Color	3	3.784

Πίνακας 3: Πίνακας metadata

Τα συνολικά πεδία που συμπληρωθήκαν ως metadata από το εξειδικευμένο προσωπικό φαίνονται παρακάτω στον Πίνακα 4, με τα περισσότερα από αυτά να είναι αριθμητικά και να περιέχουν πληροφορία για όλα τα κανάλια των εικόνων που εξάχθηκαν.

1. Color – Skin Type	26. Channel
2. Color - Color Variation	27. Fine Lines - Filter Width
3. Color - L* average	28. Fine Lines - Length (mm)
4. Color - a* average	29. Fine Lines - Score
5. Color - b* average	30. Fine Lines - Average width (mm)
6. Color - ΔL^*	31. Fine Lines - Average depth (mm)
7. Color - Δa^*	32. Fine Lines - Maximum depth (mm)
8. Color - Δb^*	33. Fine Lines - Count
9. Color - High Variation Area (mm ²)	34. Fine Lines - Indentation index
10. Color - Relative High Variation Area (%)	35. Selection
11. Color - ITA (°)	36. Channel
12. Selection	37. Folds - Filter Width
13. Channel	38. Folds - Length (mm)
14. Redness - Score	39. Folds - Average width (mm)
15. Redness - Minimum	40. Folds - Average depth (mm)
16. Redness - Average	41. Folds - Maximum depth (mm)
17. Redness - Maximum	42. Folds - Count
18. Redness - Variation	43. Folds - Indentation index
19. Redness - Uniformity (%)	44. Selection
20. Selection	45. Channel
21. Texture - Filter Width	46. Volumes - Filter Width
22. Texture - Score	47. Volumes - Threshold Level
23. Texture - Roughness Ra (μm)	48. Volumes - Volume (mm ³)
24. Texture - Roughness Rq (μm)	49. Volumes - Conforming area (mm ²)
25. Texture - Maximum height (mm)	50. Volumes - Maximum height (mm)

Πίνακας 4: Πίνακας των πεδίων των metadata

2.4 Antera 3D κάμερα

Η κάμερα που χρησιμοποιήθηκε κατά την διάρκεια των πειραμάτων όπως αναφέρθηκε παραπάνω είναι η Antera 3D®. Η Antera 3D® είναι μια προηγμένη κάμερα που έχει σχεδιαστεί και αναπτυχθεί από τη Miravex Limited για τη λήψη εικόνων υψηλής ανάλυσης που μπορούν να χρησιμοποιηθούν για την τεκμηρίωση διαφόρων θεραπειών και διαδικασιών. Η κάμερα διαθέτει ένα καινοτόμο οπτικό σύστημα και χρησιμοποιεί πολύπλοκους μαθηματικούς αλγόριθμους για τη λήψη εικόνων σε τρεις διαστάσεις, γεγονός που επιτρέπει την εξαγωγή πολύτιμων δεδομένων που σχετίζονται με το τρισδιάστατο σχήμα του δέρματος. Αυτά τα δεδομένα μπορούν να χρησιμοποιηθούν για την ποσοτικοποίηση της αποτελεσματικότητας των θεραπειών και την παρακολούθηση των αλλαγών με την πάροδο του χρόνου. Η κάμερα μπορεί να μετρήσει διάφορα χαρακτηριστικά του δέρματος, όπως η υφή, η απαλότητα το βάθος και το πλάτος των λεπτών γραμμών και των ρυτίδων.


Επιπλέον, η κάμερα Antera 3D® χρησιμοποιεί πολυφασματική ανάλυση για τη μέτρηση της μελάγχρωσης και της ερυθρότητας του δέρματος, παρέχοντας ζωτικής σημασίας πληροφορίες για τις βλάβες από τον ήλιο, τις φλέβες του νήματος και άλλα συναφή ζητήματα. Με τη βοήθεια του λογισμικού Antera, η κάμερα μπορεί να δημιουργήσει περιεκτικές και λεπτομερείς αναφορές που βοηθούν στον εντοπισμό της αποτελεσματικότητας των θεραπειών και στην παρακολούθηση της προόδου με την πάροδο του χρόνου. Αξιοποιώντας τη δύναμη της τρισδιάστατης απεικόνισης, η κάμερα Antera 3D® παρέχει ένα απaráμιλλο επίπεδο ακρίβειας απαραίτητο για την παροχή αποτελεσματικών θεραπειών και διαδικασιών [18].

Συνοπτικά, η κάμερα Antera 3D® αποτελεί συσκευή αιχμής που χρησιμοποιεί προηγμένη τεχνολογία απεικόνισης για τη λήψη τρισδιάστατων εικόνων του δέρματος υψηλής ανάλυσης. Το καινοτόμο οπτικό σύστημα και οι πολύπλοκοι αλγόριθμοι της κάμερας επιτρέπουν την εξαγωγή πολύτιμων δεδομένων που σχετίζονται με διάφορα χαρακτηριστικά του δέρματος, παρέχοντας βασικές πληροφορίες για την παρακολούθηση της προόδου με την πάροδο του χρόνου και την ποσοτικοποίηση της αποτελεσματικότητας της θεραπείας. Η πολυφασματική ανάλυση της κάμερας ενισχύει περαιτέρω τις δυνατότητές της, καθιστώντας την ένα ζωτικό εργαλείο για τους δερματολόγους και άλλους επαγγελματίες περιποίησης δέρματος [18].

Στην δική μας πειραματική διαδικασία χρησιμοποιήθηκε για να συλλέξει δεδομένα των ασθενών και την εξαγωγή των εξής 6 διαφορετικών τύπων καναλιών:

- Χρώμα: Αναφέρεται στην απόχρωση, τον κορεσμό και τη φωτεινότητα του δέρματος και μπορεί να χρησιμοποιηθεί για τον ποσοτικό προσδιορισμό της μελάγχρωσης και τον εντοπισμό περιοχών με βλάβη ή αποχρωματισμό από τον ήλιο
- Λεπτές γραμμές: Αναφέρεται σε μικρές, ρηχές ρυτίδες ή πτυχές στο δέρμα, οι οποίες μπορούν να μετρηθούν ως προς το βάθος και τη σοβαρότητα για να εκτιμηθεί η εμφάνιση της γήρανσης
- Πτυχώσεις: Αναφέρεται σε βαθύτερες γραμμές ή πτυχές στο δέρμα, όπως ρινοχειλικές πτυχές ή γραμμές μαριονέτας, οι οποίες μπορούν επίσης να μετρηθούν για να εκτιμηθεί η εμφάνιση της γήρανσης
- Ερυθρότητα: Αναφέρεται στην παρουσία ερυθρήματος ή ερυθρότητας του δέρματος, το οποίο μπορεί να μετρηθεί και να αναλυθεί για τον εντοπισμό περιοχών φλεγμονής, ερεθισμού ή άλλων δερματικών παθήσεων
- Υφή: Αναφέρεται στην ομαλότητα ή την τραχύτητα του δέρματος και μπορεί να προσδιοριστεί ποσοτικά για τον εντοπισμό περιοχών λεπτής ή χονδροειδούς υφής, καθώς και αλλαγές στην υφή με την πάροδο του χρόνου
- Όγκοι: Αναφέρεται στο σχήμα και τα περιγράμματα του προσώπου και μπορεί να μετρηθεί για να εκτιμηθούν οι αλλαγές στη δομή του προσώπου ή η απώλεια όγκου με την πάροδο του χρόνου

Ένα παράδειγμα για την οπτικοποίηση των παραπάνω τύπων εικόνας ενός τυχαίου ασθενή παρατίθεται στην Εικόνα 5.



Εικόνα 5 : Στην πάνω γραμμή από αριστερά από τα δεξιά αντιστοιχούν, 1 Χρώμα, 2. Λεπτές γραμμές 3. Πτυχώσεις και στην κάτω γραμμή από αριστερά από τα δεξιά 4. Ερυθρότητα 5. Υφή 6. Ογκοί

Κεφάλαιο 3. Επεξεργασία εικόνων

3.1 Όραση Υπολογιστών

Η όραση υπολογιστών γενικότερα αποτελεί ένα διεπιστημονικό πεδίο που επιδιώκει να εξάγει και να ερμηνεύει πληροφορίες από εικόνες ή βίντεο. Ο απώτερος στόχος είναι να περιγράψουμε με ακρίβεια τον κόσμο όπως τον βλέπουμε μέσα από μία ή περισσότερες εικόνες, αναδημιουργώντας ιδιότητες όπως το σχήμα, τη φωτεινότητα και την κατανομή των χρωμάτων. Ωστόσο, αυτό είναι ένα δύσκολο έργο και η πολυπλοκότητα του προβλήματος συχνά υποτιμάται. Το πεδίο της όρασης υπολογιστών ξεκίνησε το 1966 όταν προπτυχιακοί φοιτητές προσπάθησαν συνδέοντας μια κάμερα σε έναν υπολογιστή να κατασκευάσουν ένα πρόγραμμα για να περιγράψει την εικόνα που βλέπει η κάμερα. Αυτό το εγχείρημα ήταν πολύ πιο δύσκολο από ό,τι αρχικά είχε υπολογιστεί και οδήγησε σε μια ολόκληρη βιομηχανία υπολογιστικής όρασης.

Παρά τις προκλήσεις, η όραση υπολογιστών έχει προχωρήσει πολύ τα τελευταία 50 χρόνια και χρησιμοποιείται ευρέως για διάφορες εφαρμογές. Η οπτική αναγνώριση χαρακτήρων (OCR) είναι μια τέτοια εφαρμογή, η οποία περιλαμβάνει την ανάγνωση γραμμάτων και αριθμών, όπως έναν ταχυδρομικό κώδικα στο ταχυδρομείο ή την αναγνώριση αριθμών εγγραφής στις πινακίδες κυκλοφορίας. Πολλοί κλάδοι από την μηχανική επιθεώρηση και το εμπόριο μέχρι τα πιο σύγχρονα αναπτυσσόμενα μοντέλα μηχανικής μάθησης χρησιμοποιούν εφαρμογές της όρασης υπολογιστών για να αυτοματοποιήσουν της διαδικασίες τους.

Ένας άλλος τομέας όπου η υπολογιστική όραση έχει σημειώσει σημαντική πρόοδο τα τελευταία χρόνια είναι οι ιατρικές εφαρμογές. Με τη βοήθεια της όρασης υπολογιστή, οι ιατρικές εικόνες μπορούν να αναλυθούν και να ερμηνευτούν με μεγαλύτερη ακρίβεια, ταχύτητα και συνέπεια από ποτέ. Αυτό έφερε επανάσταση στον τρόπο με τον οποίο οι γιατροί διαγιγνώσκουν και θεραπεύουν ασθένειες και άνοιξε νέες δυνατότητες για εξατομικευμένη ιατρική.

Ένας από τους βασικούς τομείς στους οποίους η όραση υπολογιστή έχει επηρεάσει σημαντικά την ιατρική απεικόνιση είναι η ανάλυση ακτινογραφικών εικόνων όπως ακτινογραφίες, αξονικές τομογραφίες και μαγνητικές τομογραφίες. Οι αλγόριθμοι όρασης υπολογιστή μπορούν να εκπαιδευτούν ώστε να ανιχνεύουν αυτόματα ανωμαλίες σε αυτές τις εικόνες, όπως όγκους, κατάγματα και άλλες ανωμαλίες. Αυτό μπορεί να βοηθήσει τους γιατρούς να κάνουν πιο ακριβείς διαγνώσεις και να αναπτύξουν πιο αποτελεσματικά σχέδια θεραπείας. Η όραση με υπολογιστή επέτρεψε επίσης την ανάπτυξη τρισδιάστατης ιατρικής απεικόνισης, η οποία παρέχει στους γιατρούς μια πιο λεπτομερή και ακριβή εικόνα της ανατομίας του ασθενούς. Αυτό έχει αποδειχθεί ιδιαίτερα χρήσιμο στους τομείς της χειρουργικής και της ακτινοθεραπείας, όπου η ακριβής στόχευση όγκων ή άλλων ανωμαλιών είναι κρίσιμη για την επιτυχή θεραπεία.

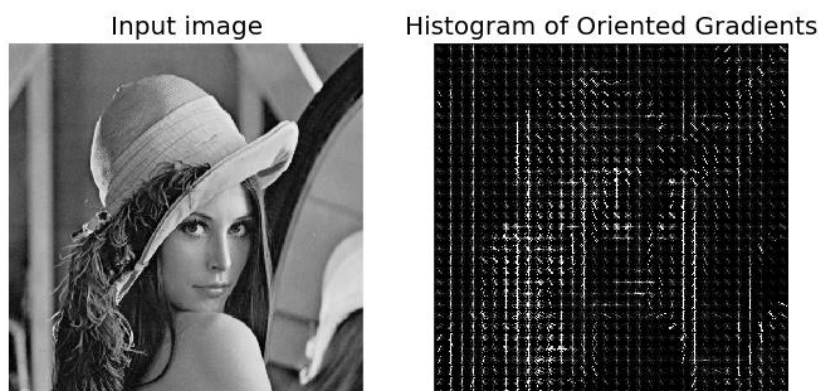
Ένας άλλος τομέας όπου η όραση υπολογιστή έχει δείξει πολλά υποσχόμενη στην ιατρική απεικόνιση είναι η ανάλυση ιστοπαθολογικών εικόνων, οι οποίες είναι εικόνες δειγμάτων ιστού που λαμβάνονται κατά τη διάρκεια βιοψιών ή χειρουργικών επεμβάσεων. Οι αλγόριθμοι υπολογιστικής όρασης μπορούν να εκπαιδευτούν ώστε να ανιχνεύουν και να ταξινομούν αυτόματα διαφορετικούς τύπους κυττάρων και ιστών, κάτι που μπορεί να

βοηθήσει τους παθολόγους να κάνουν πιο ακριβείς διαγνώσεις και να αναπτύξουν πιο αποτελεσματικά σχέδια θεραπείας.

3.2 Χαρακτηριστικά εικόνων

Η εξαγωγή χαρακτηριστικών εικόνας είναι ένα κρίσιμο βήμα στις εργασίες όρασης υπολογιστών και μηχανικής μάθησης, όπου ο στόχος είναι η εξαγωγή ουσιαστικών πληροφοριών από εικόνες για περαιτέρω επεξεργασία. Τα χαρακτηριστικά είναι ουσιαστικά μοτίβα ή χαρακτηριστικά που υπάρχουν στην εικόνα που μπορούν να χρησιμοποιηθούν για την αναγνώριση αντικειμένων, την ταξινόμηση εικόνων ή τον εντοπισμό ανωμαλιών.

Μια δημοφιλής μέθοδος εξαγωγής χαρακτηριστικών είναι το ιστόγραμμα προσανατολισμένων κλίσεων (HOG), το οποίο αντιπροσωπεύει την κατανομή των προσανατολισμών των ακμών σε μια εικόνα. Το HOG χρησιμοποιείται σε εργασίες ανίχνευσης και αναγνώρισης αντικειμένων και έχει αποδειχθεί αποτελεσματικό στην ανίχνευση ανθρώπων και οχημάτων σε εικόνες, βλέπε Εικόνα 6. Η μαθηματική έννοια του HOG περιλαμβάνει τον υπολογισμό των διαβαθμίσεων των εντάσεων της εικόνας και στη συνέχεια τη διαίρεση της εικόνας σε μικρά κελιά για να υπολογιστούν ιστογράμματα προσανατολισμών κλίσης μέσα σε κάθε κελί [19].



Εικόνα 6 Εξαγωγή χαρακτηριστικών με ιστόγραμμα προσανατολισμένων κλίσεων σε μονόχρωμη εικόνα.

Μια άλλη δημοφιλής μέθοδος εξαγωγής χαρακτηριστικών είναι ο μετασχηματισμός χαρακτηριστικών αναλλοίωτης κλίμακας (SIFT), ο οποίος βασίζεται στον εντοπισμό και την εξαγωγή βασικών σημείων σε μια εικόνα που είναι αμετάβλητα σε αλλαγές κλίμακας, περιστροφής και φωτισμού. Το SIFT χρησιμοποιείται ευρέως σε εργασίες αντιστοίχισης εικόνων και αναγνώρισης αντικειμένων. Η μαθηματική έννοια του SIFT περιλαμβάνει τον υπολογισμό των διαβαθμίσεων των εντάσεων της εικόνας σε πολλαπλές κλίμακες και στη συνέχεια τον εντοπισμό βασικών σημείων ανιχνεύοντας μέγιστα και ελάχιστα στην αναπαράσταση κλίμακας-χώρου της εικόνας [20].

Τα συνελκτικά νευρωνικά δίκτυα (CNN) είναι μια άλλη ισχυρή μέθοδος για την εξαγωγή χαρακτηριστικών εικόνας. Σε ένα CNN, το δίκτυο εκπαιδεύεται να μαθαίνει χαρακτηριστικά από τις εικόνες απευθείας, αντί να χρησιμοποιεί χειροποίητα χαρακτηριστικά. Τα

συνελικτικά επίπεδα στο δίκτυο εξάγουν τοπικά χαρακτηριστικά, όπως άκρες και υφές, ενώ τα πλήρως συνδεδεμένα επίπεδα συνδυάζουν αυτά τα χαρακτηριστικά για να σχηματίσουν καθολικές αναπαραστάσεις της εικόνας. Η μαθηματική έννοια των CNN περιλαμβάνει τη σύνθεση της εικόνας με ένα σύνολο εκπαιδευμένων φίλτρων και τη διέλευση της εξόδου μέσω μη γραμμικών συναρτήσεων ενεργοποίησης [21].

Άλλες δημοφιλείς μέθοδοι εξαγωγής χαρακτηριστικών περιλαμβάνουν τα ιστογράμματα χρώματος, τα οποία αντιπροσωπεύουν την κατανομή των τιμών χρώματος σε μια εικόνα και τα χαρακτηριστικά υφής, τα οποία αντιπροσωπεύουν μοτίβα υφής σε μια εικόνα. Τα χρωματικά ιστογράμματα χρησιμοποιούνται συχνά σε εργασίες ανάκτησης εικόνων, ενώ τα χαρακτηριστικά υφής χρησιμοποιούνται σε εργασίες όπως η ταξινόμηση υλικού και η σύνθεση υφής. Η μαθηματική έννοια των χρωματικών ιστογραμμάτων περιλαμβάνει τον κβαντισμό των τιμών χρώματος της εικόνας σε διακριτούς κάδους, ενώ τα χαρακτηριστικά υφής περιλαμβάνουν την ανάλυση της χωρικής διάταξης των εικονοστοιχείων (pixel) της εικόνας.

Όλες οι παραπάνω διαδικασίες μπορούν να εξάγουν διάφορα χαρακτηριστικά τα οποία εμπεριέχουν την πληροφορία μεταφρασμένη σε αριθμούς που είναι συγκρίσιμοι μεταξύ τους. Επομένως μερικά βασικά χαρακτηριστικά που μπορούν να εξαχθούν είναι τα παρακάτω:

1. Αντίθεση: Αυτό είναι ένα μέτρο της διαφοράς φωτεινότητας μεταξύ των φωτεινότερων και πιο σκοτεινών τμημάτων μιας εικόνας. Μια εικόνα υψηλής αντίθεσης θα έχει μεγάλη διαφορά μεταξύ των πιο ανοιχτόχρωμων και πιο σκούρων pixel, ενώ μια εικόνα χαμηλής αντίθεσης θα έχει μια μικρή διαφορά. Η αντίθεση χρησιμοποιείται συχνά ως χαρακτηριστικό σε εργασίες επεξεργασίας εικόνας, όπως η αναγνώριση αντικειμένων και η τμηματοποίηση σκηνής.
2. Υφή: Τα χαρακτηριστικά υφής περιγράφουν τη χωρική διάταξη των εντάσεων σε μια εικόνα. Μπορούν να χρησιμοποιηθούν για τον εντοπισμό μοτίβων και δομών μέσα στην εικόνα, όπως άκρες, γωνίες ή περιοχές ομοιόμορφης υφής. Τα κοινά χαρακτηριστικά υφής περιλαμβάνουν τη μήτρα συνεμφάνισης σε επίπεδο γκρι (GLCM), η οποία μετρά τη συνεμφάνιση τιμών pixel σε διαφορετικές θέσεις και προσανατολισμούς μέσα σε μια εικόνα και τη μήτρα μήκους εκτέλεσης σε επίπεδο γκρι (GLRLM), η οποία μετράει αριθμός διαδοχικών pixel σε διαφορετικά επίπεδα γκρι και προσανατολισμούς.
3. Χρώμα: Τα χαρακτηριστικά χρώματος περιγράφουν την κατανομή των χρωμάτων μέσα σε μια εικόνα. Μπορούν να χρησιμοποιηθούν για την αναγνώριση αντικειμένων ή περιοχών με βάση το χρώμα τους ή για την ανίχνευση αλλαγών στο χρώμα με την πάροδο του χρόνου. Τα κοινά χαρακτηριστικά χρώματος περιλαμβάνουν ιστογράμματα των καναλιών χρώματος (κόκκινο, πράσινο και μπλε), τα οποία παρέχουν ένα μέτρο της κατανομής των τιμών χρώματος μέσα σε μια εικόνα και τα έγχρωμα συσχετιστικά, τα οποία μετρούν τη συσχέτιση μεταξύ των χρωμάτων σε διαφορετικές θέσεις της εικόνας.
4. Σχήμα: Τα χαρακτηριστικά σχήματος περιγράφουν τις γεωμετρικές ιδιότητες των αντικειμένων μέσα σε μια εικόνα. Μπορούν να χρησιμοποιηθούν για την αναγνώριση αντικειμένων με βάση το σχήμα τους ή για την παρακολούθηση αλλαγών στο σχήμα με την πάροδο του χρόνου. Τα κοινά χαρακτηριστικά σχήματος περιλαμβάνουν τις αμετάβλητες ροπής, οι οποίες είναι μαθηματικοί περιγραφείς που καταγράφουν το σχήμα ενός αντικειμένου ανεξάρτητα από τον

προσανατολισμό, τη θέση ή το μέγεθός του, και τους περιγραφείς Fourier, που αντιπροσωπεύουν το σχήμα ενός αντικειμένου ως άθροισμα ημιτονικών και συνημιτονικών κυμάτων.

Κάποια πιο προχωρημένα αποτελούν:

1. Ενέργεια: Η ενέργεια μιας εικόνας σχετίζεται με τη συνολική φωτεινότητα και την τυπική απόκλιση των εντάσεων των pixel. Μια εικόνα με υψηλή φωτεινότητα και μεγαλύτερο εύρος εντάσεων pixel θα έχει υψηλότερη ενέργεια από μια εικόνα με χαμηλή φωτεινότητα και πιο σταθερό εύρος εντάσεων pixel.
2. Φωτεινότητα: Αντιπροσωπεύει τη συνολική φωτεινότητα μιας εικόνας. Υπολογίζεται ως η μέση τιμή της έντασης των pixel σε ολόκληρη την εικόνα. Οι υψηλές τιμές υποδεικνύουν μια φωτεινή εικόνα, ενώ οι χαμηλές τιμές μια πιο σκοτεινή εικόνα.
3. Εντροπία: Η εντροπία είναι ένα μέτρο του όγκου των πληροφοριών ή της τυχαιότητας σε μια εικόνα. Η λοξότητα και η κατανομή της ελάχιστης και της μέγιστης έντασης pixel μπορεί να επηρεάσει την εντροπία. Μια εικόνα με μεγαλύτερη ασυμμετρία στην κατανομή της έντασης των pixel ή μια λοξή κατανομή των τιμών ελάχιστης και μέγιστης έντασης θα έχει υψηλότερη εντροπία, υποδηλώνοντας μεγαλύτερη τυχαιότητα ή περιεχόμενο πληροφοριών.
4. Τυπική απόκλιση: Αυτή η δυνατότητα μετρά το μέγεθος της διακύμανσης των τιμών της έντασης των pixel στην εικόνα. Οι υψηλές τιμές υποδεικνύουν μεγαλύτερο εύρος εντάσεων pixel, ενώ οι χαμηλές τιμές υποδηλώνουν πιο σταθερό εύρος εντάσεων pixel.
5. Skewness: Αυτό το χαρακτηριστικό μετρά την ασυμμετρία της κατανομής της έντασης των pixel σε μια εικόνα. Μια θετική τιμή λοξότητας υποδηλώνει ότι η κατανομή είναι λοξή προς τα δεξιά, ενώ μια αρνητική τιμή λοξότητας δείχνει ότι η κατανομή είναι λοξή προς τα αριστερά.
6. Ελάχιστη και μέγιστη ένταση λοξότητας: Αυτή η δυνατότητα μετρά τη λοξότητα της κατανομής των τιμών της ελάχιστης και μέγιστης έντασης pixel στην εικόνα. Οι υψηλές τιμές λοξότητας για την ελάχιστη ένταση υποδεικνύουν ότι η εικόνα είναι πιο σκοτεινή συνολικά, ενώ οι υψηλές τιμές λοξότητας για τη μέγιστη ένταση υποδεικνύουν ότι η εικόνα είναι πιο φωτεινή συνολικά.

Κάθε ένα από αυτά τα χαρακτηριστικά έχει τη δική του μαθηματική ερμηνεία και μπορεί να χρησιμοποιηθεί για την εξαγωγή διαφορετικών τύπων πληροφοριών από μια εικόνα. Για παράδειγμα, η φωτεινότητα, η τυπική απόκλιση, η λοξότητα και η κύρτωση περιγράφουν την κατανομή των εντάσεων των pixel μέσα σε μια εικόνα, ενώ η αντίθεση, η υφή, το χρώμα και το σχήμα περιγράφουν ιδιότητες υψηλότερου επιπέδου όπως μοτίβα, δομές και σχήματα. Συνδυάζοντας πολλαπλές λειτουργίες, οι αλγόριθμοι μηχανικής μάθησης μπορούν να μάθουν να αναγνωρίζουν αντικείμενα, να ταξινομούν εικόνες ή να εκτελούν άλλες εργασίες με βάση οπτικές πληροφορίες.

Όλα αυτά τα χαρακτηριστικά μπορούν να χρησιμοποιηθούν για τον χαρακτηρισμό της φωτεινότητας και της αντίθεσης μιας εικόνας, η οποία μπορεί να είναι χρήσιμη για μια ποικιλία εργασιών όρασης υπολογιστή, όπως ταξινόμηση εικόνων, ανίχνευση αντικειμένων και τμηματοποίηση. Η μαθηματική σημασία αυτών των χαρακτηριστικών σχετίζεται με τις στατιστικές τους ιδιότητες, οι οποίες μπορούν να υπολογιστούν χρησιμοποιώντας διάφορους τύπους και αλγόριθμους.

Συνοπτικά, η εξαγωγή χαρακτηριστικών εικόνας είναι ένα σημαντικό βήμα σε πολλές εργασίες όρασης υπολογιστή και μηχανικής εκμάθησης. Οι διαφορετικές μέθοδοι εξαγωγής χαρακτηριστικών έχουν διαφορετικά πλεονεκτήματα και αδυναμίες και η επιλογή της μεθόδου εξαρτάται από τη συγκεκριμένη εργασία. Οι «παραδοσιακοί» μέθοδοι εξαγωγής χαρακτηριστικών όπως το HOG και το SIFT εξακολουθούν να χρησιμοποιούνται ευρέως, αλλά τα CNN έχουν δείξει μεγάλη υπόσχεση στην εκμάθηση λειτουργιών απευθείας από εικόνες.


3.3 Χρωματικοί χώροι

Για τον προσδιορισμό του χρώματος και της φωτεινότητας ενός σημείου, από τον σύνολο των εικόνων που συλλέχθηκαν μέσω της Antera3D, πρέπει να λάβουμε υπόψιν τρία διαφορετικά μήκη κύματος για τα τρία ρέματα του χώρου RGB. Για το κόκκινο παρατηρείται το μήκος R, ≈ 700 nm, για το πράσινο G, ≈ 550 nm και για το μπλε B, ≈ 440 nm. Η παραπάνω διαδικασία οφείλετε στον τρόπο που αντιλαμβάνεται το χρώμα το ανθρώπινο μάτι [22].

3.3.1 Χρώμα και ανθρώπινο μάτι

Η αντίληψη των χρωμάτων είναι μια θεμελιώδης πτυχή της ανθρώπινης όρασης, που μας επιτρέπει να διακρίνουμε και να αναγνωρίζουμε αντικείμενα με βάση τις μοναδικές φασματικές τους ιδιότητες. Το ανθρώπινο οπτικό σύστημα αποκρίνεται στο φως του οποίου το μήκος κύματος κυμαίνεται περίπου μεταξύ 400 nm και 700 nm, το οποίο αποτελεί τα ορατά μήκη κύματος του φωτός και φαίνεται και στην εικόνα 7. Μέσα σε αυτό το εύρος, υπάρχουν τρεις τύποι κωνικών φωτοϋποδοχέων στον αμφιβληστροειδή που είναι υπεύθυνοι για την αίσθηση των χρωμάτων: ο S-cone, ο M-cone και ο L-cone. Αυτοί οι κώνοι είναι ευαίσθητοι σε διαφορετικά μέρη του φάσματος του ορατού φωτός, με τον κώνο S να ανταποκρίνεται πιο έντονα στο ιώδες και το μπλε φως, τον κώνο M να ανταποκρίνεται πιο έντονα στο πράσινο και το κίτρινο φως και τον κώνο L να ανταποκρίνεται πιο έντονα στο κίτρινο και κόκκινο φως. Το μοναδικό σύνολο αποκρίσεων για κάθε μήκος κύματος είναι αυτό που επιτρέπει στο νευρικό σύστημα να διακρίνει το μήκος κύματος που προσπίπτει στον αμφιβληστροειδή.

Η περιγραφή των χρωμάτων χρησιμοποιώντας μόνο ονόματα μπορεί να είναι προβληματική, καθώς οι άνθρωποι μπορεί να χρησιμοποιούν ένα όνομα για να περιγράψουν ένα ευρύ φάσμα χρωμάτων και λίγοι άνθρωποι γνωρίζουν αρκετά ονόματα χρωμάτων για να περιγράψουν το χρωματικό φάσμα στο σύνολό του. Για την αντιμετώπιση αυτού του ζητήματος, έχει αναπτυχθεί ένα πρότυπο περιγραφής χρώματος που βασίζεται σε αριθμούς και όχι σε ονόματα. Αυτό το πρότυπο βασίζεται στη φασματική ενεργειακή πυκνότητα του φωτός που εκπέμπεται ή ανακλάται από πηγές και χρησιμοποιείται για να ποσοτικοποιήσει το χρώμα του φωτός με βάση την κατανομή της ενέργειας με το μήκος κύματος.



Εικόνα 7 : Το ορατό φάσμα φωτός.

Το ανθρώπινο οπτικό σύστημα επεξεργάζεται το χρώμα με βάση τις μοναδικές αποκρίσεις τριών τύπων κωνικών φωτοϋποδοχέων στον αμφιβληστροειδή, καθένας από τους οποίους είναι ευαίσθητος σε διαφορετικά μέρη του φάσματος του ορατού φωτός. Αυτό το σύστημα επιτρέπει στο νευρικό σύστημα να διακρίνει το μήκος κύματος του φωτός που προσπίπτει στον αμφιβληστροειδή και είναι κρίσιμο για την ικανότητά μας να αντιλαμβανόμαστε και να αναγνωρίζουμε τα χρώματα. Για την ακριβή και συνεπή περιγραφή των χρωμάτων, έχει αναπτυχθεί ένα πρότυπο περιγραφής χρώματος που βασίζεται στη φασματική ενεργειακή πυκνότητα, το οποίο χρησιμοποιείται για να ποσοτικοποιήσει το χρώμα του φωτός με βάση την κατανομή της ενέργειας με το μήκος κύματος [23].

3.3.2 Γραμμικοί χώροι χρώματος

Ένας γραμμικός χρωματικός χώρος είναι ένα χρωματικό μοντέλο όπου η σχέση μεταξύ των αριθμητικών τιμών που αντιπροσωπεύουν τα χρώματα είναι γραμμική. Με άλλα λόγια, ο διπλασιασμός της αριθμητικής τιμής ενός στοιχείου χρώματος διπλασιάζει την αντιληπτή φωτεινότητα αυτού του στοιχείου. Αυτό διαφέρει από τους μη γραμμικούς χρωματικούς χώρους, όπου η σχέση μεταξύ των αριθμητικών τιμών και της αντιληπτής φωτεινότητας είναι μη γραμμική. Σε έναν μη γραμμικό χρωματικό χώρο, ο διπλασιασμός της αριθμητικής τιμής ενός στοιχείου χρώματος ενδέχεται να μην έχει ως αποτέλεσμα τον διπλασιασμό της αντιληπτής φωτεινότητας.


Ένας από τους πιο δημοφιλείς γραμμικούς χρωματικούς χώρους είναι το γραμμικό RGB (Κόκκινο Πράσινο Μπλε). Το Linear RGB είναι μια παραλλαγή του χρωματικού χώρου RGB που έχει μια γραμμική σχέση μεταξύ των αριθμητικών τιμών και της αντιληπτής φωτεινότητας. Αυτό έρχεται σε αντίθεση με το μη γραμμικό RGB, όπως το sRGB, το οποίο έχει μια μη γραμμική σχέση μεταξύ των αριθμητικών τιμών και της αντιληπτής φωτεινότητας [22]. Στο γραμμικό RGB, ο διπλασιασμός της αριθμητικής τιμής ενός στοιχείου χρώματος διπλασιάζει την αντιληπτή φωτεινότητα αυτού του στοιχείου. Το Linear RGB χρησιμοποιείται συχνά σε επαγγελματικές εφαρμογές επεξεργασίας εικόνας, καθώς παρέχει πιο ακριβείς και προβλέψιμες τιμές χρωμάτων σε σύγκριση με τους μη γραμμικούς χρωματικούς χώρους RGB.

3.3.3 Μη-γραμμικοί χώροι χρώματος

Παρόλο που οι γραμμικοί χώροι χρώματος παρουσιάζουν πολλά πλεονεκτήματα λόγω αλγεβρική δομή τους στην πραγματικότητα δεν αντιστοιχούν καλά στην ανθρώπινη αντίληψη χρώματος. Αυτό το κενό έρχονται να καλύψουν οι μη γραμμικοί χρωματικοί χώροι, γνωστοί και ως χρωματικοί χώροι διορθωμένοι με γάμμα. Οι συγκεκριμένοι έχουν σχεδιαστεί για να μιμούνται τη μη γραμμική σχέση μεταξύ της έντασης του φωτός και της ανθρώπινης αντίληψης της φωτεινότητας. Σε μη γραμμικούς χρωματικούς χώρους, η κωδικοποίηση των χρωμάτων δεν είναι ανάλογη με την πραγματική ένταση του φωτός, αλλά μάλλον η ένταση συμπιέζεται για να ληφθεί υπόψη η μη γραμμική ευαισθησία του ανθρώπινου ματιού. Αυτή η συμπίεση επιτυγχάνεται χρησιμοποιώντας μια μαθηματική συνάρτηση που ονομάζεται συνάρτηση γάμμα, η οποία αντιστοιχίζει τις γραμμικές τιμές χρώματος σε μη γραμμικές. Ένα παράδειγμα δημοφιλούς μη γραμμικού χρωματικού χώρου είναι το sRGB, το οποίο χρησιμοποιείται ευρέως στην ψηφιακή απεικόνιση για οθόνες, εκτύπωση και τον Ιστό.

Ο HSV (Hue, Saturation, Value) είναι ένας κυλινδρικός χρωματικός χώρος που χρησιμοποιείται συχνά σε έγχρωμες εφαρμογές, όπως γραφικά, ζωγραφική και φωτογραφία. Είναι ένας μη γραμμικός χρωματικός χώρος που βασίζεται στις τρεις ιδιότητες της απόχρωσης, του κορεσμού και της τιμής. Η απόχρωση αναφέρεται στο κυρίαρχο χρώμα ενός εικονοστοιχείου, ο κορεσμός αναφέρεται στην ένταση ή την καθαρότητα του χρώματος και η τιμή αναφέρεται στη φωτεινότητα ή τη φωτεινότητα του χρώματος [22].

Για να δημιουργηθεί αυτός ο χώρος αυτός περιστρέφεται ο κυβικός χώρος συντεταγμένων του RGB ώστε η διαγώνιος $(0, 0, 0) - (1, 1, 1)$ των γκρίζων χρωμάτων να γίνει ο κάθετος άξονας στον νέο τρισδιάστατο χρωματικό χώρο. Επομένως πλέον το οριζόντιο επίπεδο κάθετο στον άξονα αποτελεί το χρωματικό επίπεδο. Η γωνία είναι η απόχρωση, H, ενώ η απόσταση από τον κάθετο άξονα είναι ο κορεσμός, S. Στο HSV, το στοιχείο απόχρωσης αντιπροσωπεύεται από μια γωνία γύρω από τον κώνου χρώματος, ενώ τα στοιχεία κορεσμού και τιμής αντιπροσωπεύονται από την απόσταση από το κέντρο του κώνου, όπως γίνεται αντιληπτό και από το Γράφημα 1 που φαίνεται παρακάτω [22]. Το HSV χρησιμοποιείται συχνά για επιλογή και χειρισμό χρώματος, καθώς παρέχει έναν διαισθητικό τρόπο προσαρμογής του χρώματος μιας εικόνας αλλάζοντας ανεξάρτητα την απόχρωση, τον κορεσμό και την τιμή.



Γράφημα 1: Ο χρωματικός χώρος HSV ως κώνος.

Κεφάλαιο 4. Εξαγωγή και επεξεργασία δεδομένων

4.1 Εισαγωγή

Η διαδικασία για την δημιουργία των δεδομένων ξεκινά από την περιθωριοποίηση των εικόνων στα σημεία διαφέροντος το οποίο πραγματοποιήθηκε με την χρήση βιβλιοθηκών της ρυθμ. Κατά την διαδικασία, περιθωριοποιούμε κάθε εικόνα με την αντίστοιχη μάσκα που περιέχει την περιοχή ενδιαφέροντος σε συνδυασμό με τα metadata που δοθήκαν από τις οπτικές παρατηρήσεις των γιατρών και σχηματίζουμε το σύνολο των δεδομένων ώστε να εκπαιδύσουμε τα μοντέλα μηχανικής μάθησης στην συνέχεια. Για την βελτιστοποίηση των αποτελεσμάτων κατά την εκπαίδευση των μοντέλων, μπορούμε να πειραματιστούμε με διάφορους τύπους δεδομένων και χώρους χρωμάτων των εικόνων. Επίσης με άλλου τύπου τεχνικές όπως η εξισορρόπηση του συνόλου δεδομένων και ο συνδυασμός διαφόρων τύπων μπορούν να αποδειχθούν εξαιρετικά σημαντικές στη βελτίωση των ποσοστών επιτυχημένων προβλέψεων.

4.2 Εξαγωγή δεδομένων

Όπως είδαμε και παραπάνω μπορούμε να εξάγουμε διάφορα χαρακτηριστικά από μια εικόνα. Στοιχεία όπως η φωτεινότητα η τυπική απόκλιση, η λοξότητα, η Κύρτωση και η ελάχιστη/μέγιστη ένταση είναι τιμές όπου μπορούν να εξαχθούν αλλά και να προσδιορίσουν μια εικόνα. Προκειμένου να εκμεταλλευτούμε τις δυνατότητες της μηχανικής μάθησης για τον εντοπισμό δερματίτιδας, θα πρέπει να εξαχθούν χαρακτηριστικά αναγνώρισης της δερματίτιδας μη ανιχνεύσιμα από το ανθρώπινο μάτι. Τα παραπάνω χαρακτηριστικά αλλά έχουν μεγάλο υπολογιστικό κόστος, επομένως, για την συγκεκριμένη μελέτη χρησιμοποιήθηκε για την εξαγωγή των χαρακτηρισμών η βιβλιοθήκη της Pyradiomics.

Το Pyradiomics είναι ένα πακέτο λογισμικού ανοιχτής πηγής που χρησιμοποιείται για την εξαγωγή ποσοτικών χαρακτηριστικών από ιατρικές εικόνες. Αναπτύχθηκε από μια ομάδα ερευνητών από το Κέντρο Καρκίνου MD Anderson του Πανεπιστημίου του Τέξας. Το Pyradiomics έχει γίνει ένα σημαντικό εργαλείο στον τομέα της ραδιοϊατρικής και έχει χρησιμοποιηθεί σε ένα ευρύ φάσμα ιατρικών εφαρμογών, συμπεριλαμβανομένης της ογκολογίας, της νευρολογίας και της καρδιολογίας³.

Το Pyradiomics παρέχει μια σειρά χαρακτηριστικών που μπορούν να εξαχθούν από ιατρικές εικόνες, συμπεριλαμβανομένων των χαρακτηριστικών πρώτης τάξης, των χαρακτηριστικών σχήματος, των χαρακτηριστικών υφής και των χαρακτηριστικών κυματιδίων. Αυτά τα χαρακτηριστικά μπορούν να χρησιμοποιηθούν για την πρόβλεψη της ανταπόκρισης στη θεραπεία, την παρακολούθηση της εξέλιξης της νόσου και τη βοήθεια στη διάγνωση. Το Pyradiomics έχει γίνει ένα σημαντικό εργαλείο για την ανάλυση ραδιοϊατρικών χαρακτηριστικών και η χρήση του έχει αυξηθεί ραγδαία τα τελευταία χρόνια.

Για την συγκεκριμένη επιστημονική μελέτη επιλέχθηκαν να εξαχθούν τα χαρακτηριστικά πρώτης τάξης που προσφέρονται από την εν λόγω βιβλιοθήκη. Τα χαρακτηριστικά πρώτης

³ <https://pyradiomics.readthedocs.io>

τάξης στο Pyradiomics αναφέρονται σε βασικά στατιστικά μέτρα μιας εικόνας, όπως ο μέσος όρος, η διακύμανση και η λοξότητα. Αυτά τα χαρακτηριστικά υπολογίζονται στις τιμές έντασης voxel μιας ιατρικής εικόνας και αντιπροσωπεύουν τη συνολική φωτεινότητα και αντίθεση της εικόνας. Τα χαρακτηριστικά πρώτης τάξης είναι ένα απλό αλλά ισχυρό εργαλείο για ανάλυση ραδιοϊατρικών χαρακτηριστικών, επειδή μπορούν να υπολογιστούν γρήγορα και αποτελεσματικά.

Ακολουθούν μερικά από τα χαρακτηριστικά πρώτης τάξης που μπορούν να εξαχθούν από μια ιατρική εικόνα χρησιμοποιώντας το Pyradiomics ⁴:

- Ενέργεια: Η μέτρηση του μεγέθους των τιμών voxel της εικόνας
- Εντροπία: Η αβεβαιότητα/τυχειότητα στην τιμή της εικόνας
- Μέσος όρος: Η μέση τιμή έντασης της εικόνας
- Τυπική απόκλιση: Ένα μέτρο της εξάπλωσης των τιμών της έντασης στην εικόνα
- Λοξότητα: Ένα μέτρο της ασυμμετρίας των τιμών της έντασης στην εικόνα
- Κύρτωση: Μέτρο της αιχμής των τιμών της έντασης στην εικόνα
- Διακύμανση : Ο μέσος όρος των τετραγωνικών αποστάσεων κάθε τιμής της έντασης από τη μέση τιμή
- Ελάχιστη και μέγιστη ένταση: Η χαμηλότερη και η υψηλότερη τιμή έντασης στην εικόνα
- Ομοιομορφία: Το μέτρο του αθροίσματος των τετραγώνων κάθε τιμής έντασης

Τα χαρακτηριστικά πρώτης τάξης παρέχουν σημαντικές πληροφορίες σχετικά με τη συνολική κατανομή έντασης μιας ιατρικής εικόνας, η οποία μπορεί να χρησιμοποιηθεί για την αξιολόγηση της ποιότητας της εικόνας, την ανίχνευση τεχνουργημάτων ή ανωμαλιών και την παροχή βάσης για σύγκριση με άλλα χαρακτηριστικά εικόνας. Παρέχοντας αυτές τις πληροφορίες, τα χαρακτηριστικά πρώτης τάξης μπορούν να βοηθήσουν στην καθοδήγηση της μετέπειτα ανάλυσης και στην παροχή σημαντικών πληροφοριών για τις διαδικασίες της νόσου.

4.3 Εξισορρόπηση συνόλου δεδομένων

Η εκπαίδευση μοντέλων μηχανικής μάθησης με μη ισορροπημένο σύνολο δεδομένων μπορεί να δημιουργήσει πολλές προκλήσεις. Σε ένα μη ισορροπημένο σύνολο δεδομένων, ο αριθμός των περιπτώσεων σε μια κλάση είναι σημαντικά υψηλότερος από τις άλλες, οδηγώντας σε προκατάληψη προς την πλειοψηφική τάξη. Αυτό μπορεί να προκαλέσει το μοντέλο να μάθει λανθασμένα μοτίβα και να ταξινομήσει εσφαλμένα παρουσίες από την τάξη μειοψηφίας. Για παράδειγμα, εάν έχουμε ένα σύνολο δεδομένων 1000 παρουσιών, από τις οποίες οι 900 ανήκουν στην κλάση A και οι 100 στην κατηγορία B, τότε ένα μοντέλο που εκπαιδεύεται σε αυτό το σύνολο δεδομένων μπορεί να ταξινομήσει όλες τις παρουσίες ως κλάση A χωρίς καν να λάβει υπόψη τα χαρακτηριστικά, και θα έδινε υψηλή ακρίβεια λόγω της σωστής ταξινόμησης της πλειοψηφικής τάξης. Αυτό το ζήτημα είναι ιδιαίτερα προβληματικό σε εργασίες ταξινόμησης όπου ο προσδιορισμός της μειονοτικής τάξης είναι σημαντικός, όπως ο εντοπισμός απάτης ή η διάγνωση ασθενειών [24].

⁴ <https://pyradiomics.readthedocs.io>

Μια κοινή προσέγγιση για την αντιμετώπιση αυτού του ζητήματος είναι η εξισορρόπηση του συνόλου δεδομένων είτε με υποδειγματοληψία της πλειοψηφικής τάξης είτε υπερδειγματοληψία της κατηγορίας μειοψηφίας. Η υποδειγματοληψία περιλαμβάνει την τυχαία αφαίρεση παρουσιών από την πλειοψηφική τάξη, μειώνοντας έτσι την ανισορροπία της τάξης. Ωστόσο, αυτό μπορεί να οδηγήσει σε απώλεια πολύτιμων πληροφοριών και ως εκ τούτου σε μειωμένη ακρίβεια του μοντέλου. Η υπερδειγματοληψία περιλαμβάνει την αναπαραγωγή περιπτώσεων από την τάξη της μειονότητας, αυξάνοντας έτσι τη συχνότητά της. Ωστόσο, αυτή η προσέγγιση μπορεί να οδηγήσει σε υπερπροσαρμογή και μειωμένη γενίκευση του μοντέλου σε νέα δεδομένα [24].

Μια άλλη προσέγγιση είναι η χρήση αλγορίθμων μάθησης με ευαισθησία στο κόστος, οι οποίοι εκχωρούν διαφορετικά βάρη σε διαφορετικές τάξεις με βάση τη συχνότητά τους. Αυτό διασφαλίζει ότι το μοντέλο τιμωρείται περισσότερο για εσφαλμένη ταξινόμηση περιπτώσεων από την τάξη της μειονότητας, και ως εκ τούτου δίνει μεγαλύτερη σημασία στην τάξη μειοψηφίας.

Στην δική μας περίπτωση δοκιμαστήκαν και οι τρεις παραπάνω προσεγγίσεις, με την υπερδειγματοληψία να αποδίδει της περισσότερες φορές καλύτερα δεδομένου του μικρού όγκου δεδομένων που διαθέτουμε.

Κεφάλαιο 5. Νευρωνικά Δίκτυα και Μηχανική Μάθηση

5.1 Εισαγωγή

Η μηχανική μάθηση είναι ένα ταχέως αναπτυσσόμενο πεδίο επιστημονικής έρευνας που εστιάζει στην ανάπτυξη συστημάτων και μεθόδων που μπορούν να «μάθουν» από νέα δεδομένα προκειμένου να βελτιώσουν την απόδοσή τους σε συγκεκριμένες εργασίες. Ως κλάδος της τεχνητής νοημοσύνης, η μηχανική μάθηση περιλαμβάνει τη χρήση αλγορίθμων για τη δημιουργία μοντέλων που μπορούν να εκπαιδευτούν χρησιμοποιώντας δεδομένα παρατήρησης και καταγραφής, με στόχο την παραγωγή ακριβών προβλέψεων ή/και αποφάσεων χωρίς την ανάγκη ρητού προγραμματισμού για κάθε εργασία. Οι αλγόριθμοι μηχανικής μάθησης χρησιμοποιούνται σε ένα ευρύ φάσμα εφαρμογών, ιδιαίτερα σε περιπτώσεις όπου είναι δύσκολο ή ανέφικτο να αναπτυχθούν συμβατικοί αλγόριθμοι για την εκτέλεση συγκεκριμένων εργασιών.

Μία από τις πιο ισχυρές μεθόδους που χρησιμοποιούνται στη μηχανική μάθηση είναι τα νευρωνικά δίκτυα, τα οποία έχουν σχεδιαστεί για να προσομοιώνουν τη λειτουργία του ανθρώπινου εγκεφάλου. Αυτά τα δίκτυα αποτελούνται από πολλαπλά στρώματα διασυνδεδεμένων κόμβων που επεξεργάζονται πληροφορίες με τρόπο παρόμοιο με τον τρόπο που λειτουργούν οι νευρώνες στον εγκέφαλο. Τα νευρωνικά δίκτυα είναι ιδιαίτερα χρήσιμα στην επεξεργασία πολύπλοκων συνόλων δεδομένων, συμπεριλαμβανομένων εικόνων, ήχου και φυσικής γλώσσας, και έχουν οδηγήσει στην ανάπτυξη εφαρμογών σε πεδία όπως η αναγνώριση εικόνας και ομιλίας, η επεξεργασία φυσικής γλώσσας και τα αυτόνομα συστήματα.

Παρά τα πολλά πλεονεκτήματά τους, η μηχανική μάθηση και τα νευρωνικά δίκτυα παρουσιάζουν επίσης αρκετές προκλήσεις. Μία από τις μεγαλύτερες προκλήσεις είναι η ανάγκη για μεγάλες ποσότητες δεδομένων υψηλής ποιότητας για την εκπαίδευση μοντέλων μηχανικής μάθησης. Οι Διαδικασίες συλλογής αυτών των δεδομένων μπορεί να είναι δύσκολες και δαπανηρές, ιδιαίτερα σε περιπτώσεις όπου τα υποκείμενα δεδομένα αλλάζουν συνεχώς. Επιπλέον, τα μοντέλα μηχανικής μάθησης μπορεί να είναι πολύπλοκα και δύσκολα στην ερμηνεία, γεγονός που μπορεί να κάνει δύσκολο τον εντοπισμό και τη διόρθωση σφαλμάτων.

Ωστόσο, τα πιθανά οφέλη της μηχανικής μάθησης και των νευρωνικών δικτύων είναι τεράστια. Η μηχανική εκμάθηση έχει την ικανότητα να βελτιώνει την απόδοση με την πάροδο του χρόνου, καθώς τα μοντέλα γίνονται πιο εκλεπτυσμένα και οι προβλέψεις γίνονται πιο ακριβείς με τη συμπερίληψη περισσότερων δεδομένων. Αυτό το καθιστά ιδιαίτερα χρήσιμο σε καταστάσεις όπου τα υποκείμενα δεδομένα αλλάζουν συνεχώς, όπως σε χρηματοπιστωτικές αγορές, πρόβλεψη καιρού ή ανάλυση μέσων κοινωνικής δικτύωσης. Επιπλέον, η μηχανική μάθηση μπορεί να προσφέρει πολύτιμες πληροφορίες για πολύπλοκα σύνολα δεδομένων που θα ήταν δύσκολο να αναλυθούν χρησιμοποιώντας παραδοσιακές στατιστικές μεθόδους, βοηθώντας τους οργανισμούς να λαμβάνουν καλύτερες αποφάσεις.

5.2 Κατηγορίες μηχανικής μάθησης

Η μηχανική μάθηση έχει γίνει ένα ζωτικό εργαλείο για πολλούς κλάδους, από τη χρηματοδότηση μέχρι την υγειονομική περίθαλψη και το λιανικό εμπόριο. Καθώς ο όγκος των δεδομένων που παράγουμε αυξάνεται εκθετικά, η μηχανική μάθηση είναι ολοένα και πιο απαραίτητη για να μας βοηθήσει να κατανοήσουμε όλα αυτά. Ωστόσο, δεν είναι όλα τα προβλήματα μηχανικής εκμάθησης ίδια. Ανάλογα με τη συγκεκριμένη εργασία, διαφορετικές κατηγορίες αλγορίθμων μηχανικής μάθησης μπορεί να είναι πιο αποτελεσματικές από άλλες.

Υπάρχουν πολλές διαφορετικές κατηγορίες αλγορίθμων μηχανικής μάθησης, ο καθένας με τα δικά του δυνατά και αδύνατα σημεία. Μερικές από τις πιο κοινές κατηγορίες είναι:

- Παλινδρόμηση (Regression): Αναφέρεται σε προβλήματα που απαιτούν την πρόβλεψη μιας συνεχούς αριθμητικής τιμής. Για παράδειγμα, η πρόβλεψη της τιμής ενός σπιτιού με βάση τα χαρακτηριστικά του.
- Ταξινόμηση (Classification): Κυρίως υποσύνολο προβλημάτων που αναφέρεται σε προβλήματα που απαιτούν ταξινόμηση δεδομένων σε διαφορετικές κλάσεις. Εάν οι κλάσεις είναι δύο, το πρόβλημα ονομάζεται δυαδική ταξινόμηση. Για περισσότερες από δύο κατηγορίες, ονομάζεται multiclass ταξινόμηση. Ένα παράδειγμα είναι η ταξινόμηση ασθενών σε υγιείς και μη ανάλογα με τα συμπτώμα τους.
- Ομαδοποίηση (Clustering): Αυτό περιλαμβάνει την εύρεση μιας δομής ή μοτίβου σε μια συλλογή δεδομένων χωρίς κατηγορίες. Για παράδειγμα, ομαδοποίηση παρόμοιων ταινιών ή τραγουδιών για μια υπηρεσία ροής.
- Ανίχνευση ανωμαλιών (Anomaly detection): Σε αυτό το υποσύνολο εμπεριέχεται ο εντοπισμός ακραίων τιμών σε ένα σύνολο δεδομένων, οι οποίες είναι τιμές που δεν θεωρούνται λογικές και αποκλίνουν από τις υπόλοιπες. Ένα παράδειγμα αυτού του είδους προβλήματος είναι ο εντοπισμός ύποπτων συναλλαγών για απάτη με πιστωτικές κάρτες.
- Μείωση διαστάσεων (Dimensionality reduction): Αυτό περιλαμβάνει τη μείωση του αριθμού των μεταβλητών εισόδου, οι οποίες είναι τα χαρακτηριστικά ενός συνόλου δεδομένων. Το πρόβλημα της μείωσης των διαστάσεων αντιμετωπίζεται χρησιμοποιώντας τεχνικές που μειώνουν τον αριθμό των μεταβλητών εισόδου.

Αυτοί οι διαφορετικοί τύποι αλγορίθμων μηχανικής μάθησης μπορούν να εφαρμοστούν σε ένα ευρύ φάσμα προβλημάτων του πραγματικού κόσμου. Οι αλγόριθμοι παλινδρόμησης, για παράδειγμα, μπορούν να χρησιμοποιηθούν για την πρόβλεψη τιμών μετοχών ή αξιών ακινήτων με βάση ιστορικά δεδομένα. Οι αλγόριθμοι ταξινόμησης μπορούν να βοηθήσουν στον εντοπισμό δόλιων συναλλαγών με πιστωτικές κάρτες ή στην πρόβλεψη της εκτροπής πελατών σε μια επιχείρηση που βασίζεται σε συνδρομές. Οι αλγόριθμοι ομαδοποίησης μπορούν να χρησιμοποιηθούν για την τμηματοποίηση των πελατών σε διαφορετικές ομάδες για στοχευμένες καμπάνιες μάρκετινγκ. Οι αλγόριθμοι ανίχνευσης ανωμαλιών είναι χρήσιμοι για τον εντοπισμό πιθανών παραβιάσεων ασφάλειας σε δίκτυα υπολογιστών ή για τον εντοπισμό ελαττωμάτων στις διαδικασίες παραγωγής. Και οι αλγόριθμοι μείωσης διαστάσεων μπορούν να βοηθήσουν τους ερευνητές να αναλύσουν πολύπλοκα ιατρικά σύνολα δεδομένων ή να κατανοήσουν μεγάλες ποσότητες δεδομένων κειμένου.

Οι αλγόριθμοι μηχανικής μάθησης εκπαιδεύονται χρησιμοποιώντας διαφορετικούς τύπους δεδομένων, τα οποία κατηγοριοποιούνται με βάση τον τύπο των δεδομένων που αντιπροσωπεύουν. Οι δυνατότητες στις οποίες βασίζονται οι αλγόριθμοι μηχανικής μάθησης μπορεί να είναι συνεχείς, κατηγορικές ή δυαδικές. Τα συνεχή δεδομένα αναφέρονται σε αριθμούς, τα κατηγορικά δεδομένα αναφέρονται σε δεδομένα συμβολοσειρών και τα δυαδικά δεδομένα αναφέρονται σε δεδομένα που λαμβάνουν τιμή 0 ή 1.

Η κατηγοριοποίηση των διαδικασιών γίνεται με βάση την παρουσία ή μη εκπαιδευτή κατά τη διάρκεια της μαθησιακής διαδικασίας. Η καθοδηγούμενη μάθηση ή η εποπτευόμενη μάθηση αναφέρεται σε διαδικασίες μάθησης που περιλαμβάνουν την παρουσία ενός εκπαιδευτή, ενώ η μάθηση χωρίς επίβλεψη αναφέρεται σε διαδικασίες μάθησης που δεν περιλαμβάνουν εκπαιδευτή.

Επομένως, οι διάφορες κατηγορίες αλγορίθμων μηχανικής μάθησης παρέχουν μια ισχυρή εργαλειοθήκη για την επίλυση ενός ευρέος φάσματος προβλημάτων του πραγματικού κόσμου. Ανάλογα με τη συγκεκριμένη εργασία, διαφορετικές κατηγορίες αλγορίθμων μπορεί να είναι πιο αποτελεσματικές από άλλες. Κατανοώντας τα δυνατά και τα αδύνατα σημεία κάθε τύπου αλγορίθμου, μπορούμε να επιλέξουμε το καλύτερο εργαλείο για τη δουλειά και να συνεχίσουμε να ξεκλειδώνουμε τη δύναμη της μηχανικής μάθησης στην καθημερινή μας ζωή.

5.2.1 Εποπτευόμενη μάθηση

Η εποπτευόμενη μάθηση, γνωστή και ως καθοδηγούμενη μάθηση, είναι μια θεμελιώδης έννοια στη μηχανική μάθηση. Περιλαμβάνει τη δημιουργία μοντέλων χρησιμοποιώντας δεδομένα εκπαίδευσης με ετικέτα, όπου παρέχεται η επιθυμητή έξοδος για κάθε είσοδο και αυτά τα μοντέλα μπορούν στη συνέχεια να χρησιμοποιηθούν για την ταξινόμηση νέων, χωρίς ετικέτα δεδομένων. Η διαθεσιμότητα των δεδομένων με ετικέτα είναι ένα κρίσιμο χαρακτηριστικό της εποπτευόμενης μάθησης, καθιστώντας την μια από τις πιο ευρέως χρησιμοποιούμενες μεθοδολογίες στη μηχανική μάθηση.

Ο στόχος της εποπτευόμενης μάθησης είναι να καθιερώσει τη σχέση μεταξύ δεδομένων εισόδου και εξόδου με βάση παραδείγματα εκπαίδευσης στα οποία κάθε είσοδος αντιστοιχίζεται στην αντίστοιχη έξοδο. Με αυτόν τον τρόπο, ένα τεχνητό σύστημα μπορεί να μάθει τη χαρτογράφηση εισόδου-εξόδου και να προβλέψει την έξοδο του συστήματος για νέες, άρατες εισόδους δεδομένων χωρίς ετικέτες. Εάν η έξοδος παίρνει διακριτές τιμές από ένα πεπερασμένο σύνολο τιμών, οι οποίες υποδεικνύουν τις κατηγορίες προβλημάτων, η διαμορφωμένη αντιστοίχιση οδηγεί σε ταξινόμηση των δεδομένων εισόδου. Από την άλλη πλευρά, εάν η έξοδος παίρνει συνεχείς τιμές, η αντιστοίχιση οδηγεί σε παλινδρόμηση των δεδομένων εισόδου.

Στην εποπτευόμενη μάθηση, ένας δάσκαλος έχει γνώση του περιβάλλοντος, το οποίο αντιπροσωπεύεται από ένα σύνολο παραδειγμάτων εισαγωγής με επισημασμένα αποτελέσματα. Ωστόσο, το περιβάλλον είναι άγνωστο στο νευρωνικό δίκτυο. Εισάγοντας ένα διάνυσμα εκπαίδευσης, ο εκπαιδευτής παρέχει στο νευρωνικό δίκτυο την επιθυμητή απόκριση για το δεδομένο διάνυσμα. Οι παράμετροι του νευρωνικού δικτύου, δηλαδή τα συναπτικά βάρη του, προσαρμόζονται υπό τη συνδυασμένη επίδραση του διανύσματος εκπαίδευσης και του σήματος σφάλματος, το οποίο ορίζεται ως η διαφορά μεταξύ της

επιθυμητής απόκρισης και της πραγματικής απόκρισης του δικτύου. Η προσαρμογή εκτελείται επαναληπτικά και το νευρωνικό δίκτυο θα προσομοιώσει τελικά τη συμπεριφορά του εκπαιδευτή.

Η γνώση του περιβάλλοντος που διαθέτει ο εκπαιδευτής μεταφέρεται στο νευρωνικό δίκτυο μέσω της εκπαίδευσης και αποθηκεύεται με τη μορφή σταθερών συναπτικών βαρών, τα οποία αντιπροσωπεύουν τη μακροπρόθεσμη μνήμη. Όταν επιτευχθεί αυτή η συνθήκη, μπορούμε να απαλλαγούμε από τον εκπαιδευτή και να αφήσουμε το νευρωνικό δίκτυο να αντιμετωπίσει το περιβάλλον εντελώς μόνο του, παράγοντας προβλέψεις για δεδομένα εισόδου για τα οποία δεν γνωρίζει την επιθυμητή απόκριση.

Αξίζει να σημειωθεί ότι η ελαχιστοποίηση του προπονητικού σφάλματος δεν εξασφαλίζει απαραίτητα καλή απόδοση κατά τη διάρκεια της δοκιμής, δηλαδή την κατάσταση όπου το σύστημα εκπαιδεύεται και αξιολογείται με βάση τις προβλέψεις του σε άγνωστα δεδομένα, δηλαδή δεδομένα που δεν χρησιμοποιούνται κατά την εκπαίδευση. Ο κύριος λόγος για αυτό το φαινόμενο είναι η πιθανή «υπερπροσαρμογή» του συστήματος στα δεδομένα εκπαίδευσης, δηλαδή η περιττή πολυπλοκότητα του μαθημένου συστήματος κατά τον προσδιορισμό της αντιστοίχισης μεταξύ εισόδου και εξόδου. Ένας καλός αλγόριθμος μάθησης θα πρέπει να έχει καλή γενίκευση, πράγμα που σημαίνει ότι θα πρέπει να ισορροπεί μεταξύ της ελαχιστοποίησης του προπονητικού σφάλματος και της πολυπλοκότητάς του για βέλτιστη απόδοση.

Υπάρχουν διαφορετικές προσεγγίσεις για το σχεδιασμό ενός συστήματος εποπτευόμενης μάθησης. Μερικές από τις πιο γνωστές προσεγγίσεις είναι οι βασισμένες στη λογική, το πολυστρωματικό perceptron, η στατιστική μάθηση, η βασισμένη σε παράδειγμα, οι μηχανές διανυσμάτων υποστήριξης και η ενίσχυση. Κάθε προσέγγιση έχει τα δικά της πλεονεκτήματα και μειονεκτήματα και είναι η πλέον κατάλληλη για διαφορετικούς τύπους προβλημάτων. Η επιλογή μιας συγκεκριμένης προσέγγισης εξαρτάται από το συγκεκριμένο πρόβλημα και τα διαθέσιμα δεδομένα.

Συμπερασματικά, η εποπτευόμενη μάθηση είναι μια κρίσιμη μεθοδολογία στη μηχανική μάθηση που περιλαμβάνει τη δημιουργία μοντέλων χρησιμοποιώντας δεδομένα εκπαίδευσης με ετικέτα για την ταξινόμηση νέων, χωρίς ετικέτα δεδομένων. Η διαθεσιμότητα επισημασμένων δεδομένων είναι ένα κρίσιμο χαρακτηριστικό της εποπτευόμενης μάθησης. Είναι απαραίτητο να υπάρχει ισορροπία μεταξύ της ελαχιστοποίησης του προπονητικού λάθους και της πολυπλοκότητας του μαθημένου συστήματος για βέλτιστη απόδοση. Μπορούν να χρησιμοποιηθούν διαφορετικές προσεγγίσεις για το σχεδιασμό ενός εποπτευόμενου συστήματος μάθησης και η επιλογή της προσέγγισης εξαρτάται από το συγκεκριμένο πρόβλημα και τα διαθέσιμα δεδομένα [25].

5.2.2 Μάθηση χωρίς επίβλεψη

Η μάθηση χωρίς επίβλεψη είναι ένας άλλος τύπος μηχανικής μάθησης, σε αντίθεση με την εποπτευόμενη μάθηση. Σε αντίθεση με την εποπτευόμενη μάθηση, η μάθηση χωρίς επίβλεψη περιλαμβάνει εργασία με δεδομένα χωρίς ετικέτα, όπου τα δεδομένα εισόδου δεν είναι προεπισημασμένα με την επιθυμητή έξοδο. Ο στόχος της μάθησης χωρίς επίβλεψη είναι να βρει μοτίβα ή δομή μέσα στα δεδομένα χωρίς καμία συγκεκριμένη γνώση για το ποια μπορεί να είναι τα μοτίβα ή η δομή.

Μία από τις πιο κοινές μεθόδους που χρησιμοποιούνται στην μάθηση χωρίς επίβλεψη είναι η ομαδοποίηση, η οποία περιλαμβάνει την ομαδοποίηση σημείων δεδομένων που είναι παρόμοια μεταξύ τους με βάση κάποια μέτρηση ομοιότητας. Η ομαδοποίηση μπορεί να χρησιμοποιηθεί για ένα ευρύ φάσμα εργασιών, όπως τμηματοποίηση πελατών ή τμηματοποίηση εικόνας. Μια άλλη κοινή μέθοδος που χρησιμοποιείται στην μάθηση χωρίς επίβλεψη είναι η μείωση διαστάσεων, η οποία περιλαμβάνει τη μείωση του αριθμού των χαρακτηριστικών σε ένα σύνολο δεδομένων, διατηρώντας παράλληλα όσο το δυνατόν περισσότερες χρήσιμες πληροφορίες. Αυτό μπορεί να είναι χρήσιμο για εργασίες όπως συμπίεση δεδομένων ή οπτικοποίηση.

Γενικά, η μάθηση χωρίς επίβλεψη είναι χρήσιμη όταν τα δεδομένα είναι πολύ περίπλοκα για να επισημανθούν χειροκίνητα ή όταν η επιθυμητή έξοδος είναι άγνωστη. Μπορεί επίσης να χρησιμοποιηθεί ως βήμα προεπεξεργασίας για εποπτευόμενη μάθηση, καθώς μπορεί να βοηθήσει στον εντοπισμό σχετικών χαρακτηριστικών ή στη μείωση της διάστασης των δεδομένων. Συνολικά, ενώ η μάθηση χωρίς επίβλεψη μπορεί να μην είναι τόσο διαισθητική όσο η εποπτευόμενη μάθηση, μπορεί να εξακολουθεί να είναι ένα πολύτιμο εργαλείο για την εξερεύνηση και την κατανόηση πολύπλοκων συνόλων δεδομένων [25].

5.2.3 Ενισχυτική Μάθηση

Η Ενισχυτική Μάθηση (RL) είναι ένα υποπεδίο της μηχανικής μάθησης που ασχολείται με το πώς ένας πράκτορας πρέπει να αναλαμβάνει ενέργειες σε ένα περιβάλλον για να μεγιστοποιήσει κάποια έννοια ανταμοιβής. Σε αντίθεση με την εποπτευόμενη μάθηση, ο πράκτορας δεν έχει πρόσβαση σε δεδομένα εκπαίδευσης με ετικέτα, και σε αντίθεση με την μάθηση χωρίς επίβλεψη, υπάρχουν σαφείς ανταμοιβές και τιμωρίες για τις ενέργειες του πράκτορα. Το RL είναι ένα βασικό συστατικό της τεχνητής νοημοσύνης και έχει πολλές εφαρμογές, όπως ρομποτική, παιχνίδια, χρηματοδότηση και συστήματα συστάσεων.

Η θεμελιώδης έννοια του RL είναι η ιδέα ενός πράκτορα που αλληλεπιδρά με ένα περιβάλλον. Ο πράκτορας παρατηρεί την τρέχουσα κατάσταση του περιβάλλοντος, επιλέγει μια ενέργεια με βάση την τρέχουσα κατάσταση και το περιβάλλον ανταποκρίνεται με μια νέα κατάσταση και ένα σήμα ανταμοιβής. Στη συνέχεια, ο πράκτορας ενημερώνει το εσωτερικό του μοντέλο του περιβάλλοντος βάσει αυτής της εμπειρίας και επιλέγει την επόμενη ενέργεια κ.ο.κ. Ο στόχος είναι να βρεθεί η βέλτιστη πολιτική, η οποία είναι μια χαρτογράφηση από τις καταστάσεις σε ενέργειες που μεγιστοποιεί την αναμενόμενη σωρευτική ανταμοιβή με την πάροδο του χρόνου.

Το RL διαφέρει από την εποπτευόμενη μάθηση στο ότι δεν υπάρχουν επισημασμένα δεδομένα εκπαίδευσης από τα οποία μπορείτε να μάθετε. Αντίθετα, ο πράκτορας μαθαίνει από τη δοκιμή και το λάθος, δοκιμάζοντας διαφορετικές ενέργειες και παρατηρώντας τις συνέπειες. Η απόδοση του πράκτορα αξιολογείται με βάση τη συνολική ανταμοιβή που λαμβάνει με την πάροδο του χρόνου. Ο στόχος του πράκτορα είναι να μεγιστοποιήσει την αναμενόμενη σωρευτική ανταμοιβή, η οποία απαιτεί εξισορρόπηση των βραχυπρόθεσμων ανταμοιβών με τους μακροπρόθεσμους στόχους.

Μία από τις βασικές προκλήσεις του RL είναι ο συμβιβασμός εξερεύνησης-εκμετάλλευσης. Ο πράκτορας πρέπει να αποφασίσει εάν θα επιλέξει ενέργειες που είναι γνωστό ότι είναι καλές (εκμετάλλευση) ή θα δοκιμάσει νέες ενέργειες για να μάθει περισσότερα για το

περιβάλλον (εξερεύνηση). Εάν ο πράκτορας εκμεταλλευτεί μόνο τις τρέχουσες γνώσεις του, μπορεί να χάσει καλύτερες ενέργειες που δεν έχει δοκιμάσει ακόμη. Από την άλλη πλευρά, εάν ο πράκτορας εξερευνήσει μόνο, μπορεί να χάσει χρόνο και να χάσει βραχυπρόθεσμες ανταμοιβές. Οι αλγόριθμοι RL πρέπει να εξισορροπούν αυτήν την ανταλλαγή για να μαθαίνουν αποτελεσματικά.

Υπάρχουν αρκετοί δημοφιλείς αλγόριθμοι για το RL, συμπεριλαμβανομένων των μεθόδων Q-learning, SARSA και μεθόδων κριτικού ηθοποιού. Το Q-learning είναι μια μέθοδος που βασίζεται σε τιμές που μαθαίνει τη βέλτιστη συνάρτηση τιμής για κάθε ζεύγος κατάστασης-δράσης. Το SARSA είναι επίσης μια μέθοδος που βασίζεται σε αξία, αλλά μαθαίνει τη συνάρτηση τιμής χρησιμοποιώντας μια πολιτική που βασίζεται στη συμπεριφορά του πράκτορα. Οι μέθοδοι που ασκούν κριτική συνδυάζουν μεθόδους που βασίζονται σε αξία και πολιτικές και χρησιμοποιούν δύο νευρωνικά δίκτυα: ένα για την αναπαράσταση της πολιτικής και ένα για την αναπαράσταση της συνάρτησης αξίας.

Συνολικά, η Ενισχυτική Μάθηση είναι ένα υποπεδίο της μηχανικής μάθησης που ασχολείται με παράγοντες που αλληλεπιδρούν με ένα περιβάλλον για τη μεγιστοποίηση της σωρευτικής ανταμοιβής. Η RL διαφέρει από την εποπτευόμενη και χωρίς επίβλεψη μάθηση, επειδή δεν υπάρχουν επισημασμένα δεδομένα εκπαίδευσης και σαφείς ανταμοιβές και τιμωρίες για τις ενέργειες του πράκτορα. Οι αλγόριθμοι RL πρέπει να εξισορροπούν την εξερεύνηση και την εκμετάλλευση για να μαθαίνουν αποτελεσματικά. Υπάρχουν αρκετοί δημοφιλείς αλγόριθμοι RL, συμπεριλαμβανομένων των μεθόδων Q-learning, SARSA και μεθόδων κριτικού ηθοποιού. Το RL έχει πολλές εφαρμογές στην τεχνητή νοημοσύνη, συμπεριλαμβανομένων των συστημάτων ρομποτικής, παιχνιδιών, χρηματοδότησης και συστάσεων [25].


5.3 Μοντέλα Μηχανικής Μάθησης

5.3.1 Decision Tree

Τα δέντρα αποφάσεων είναι μια δημοφιλής τεχνική μηχανικής μάθησης που χρησιμοποιείται τόσο για εργασίες ταξινόμησης όσο και για εργασίες παλινδρόμησης. Ένα δέντρο απόφασης είναι ένα ιεραρχικό μοντέλο που αποτελείται από κόμβους απόφασης και κόμβους φύλλων, όπου κάθε κόμβος απόφασης αντιπροσωπεύει μια απόφαση που βασίζεται σε ένα χαρακτηριστικό ή χαρακτηριστικό και κάθε κόμβος φύλλου αντιπροσωπεύει μια ετικέτα κλάσης ή μια αριθμητική τιμή. Ο στόχος της δημιουργίας ενός δέντρου αποφάσεων είναι να χωρίσει τα δεδομένα σε ομοιογενή υποσύνολα λαμβάνοντας μια ακολουθία αποφάσεων με βάση τις τιμές χαρακτηριστικών και στη συνέχεια να εκχωρήσει μια ετικέτα ή μια τιμή σε κάθε κόμβο φύλλου.

Η διαδικασία δημιουργίας ενός δέντρου αποφάσεων περιλαμβάνει την επιλογή του καλύτερου χαρακτηριστικού για τον διαχωρισμό των δεδομένων σε κάθε κόμβο απόφασης με βάση ένα κριτήριο διαχωρισμού. Υπάρχουν διαφορετικά κριτήρια διαχωρισμού που μπορούν να χρησιμοποιηθούν, όπως κέρδος πληροφοριών, αναλογία κέρδους και δείκτης Gini. Το επιλεγμένο χαρακτηριστικό χρησιμοποιείται στη συνέχεια για να χωρίσει τα δεδομένα σε δύο ή περισσότερα υποσύνολα, καθένα από τα οποία επεξεργάζεται

αναδρομικά μέχρι να ικανοποιηθεί ένα κριτήριο διακοπής, όπως η επίτευξη ενός ελάχιστου αριθμού δειγμάτων σε έναν κόμβο ή ενός μέγιστου βάθους του δέντρου.



Εικόνα 8: Decision Tree flow chart⁵.

Τα δέντρα απόφασης έχουν πολλά πλεονεκτήματα, συμπεριλαμβανομένης της ερμηνευτικότητάς τους, καθώς το δέντρο που προκύπτει μπορεί να οπτικοποιηθεί και να κατανοηθεί εύκολα από τον άνθρωπο. Επιπλέον, τα δέντρα αποφάσεων μπορούν να χειριστούν τόσο αριθμητικά όσο και κατηγορικά χαρακτηριστικά, καθώς και τιμές που λείπουν. Μπορούν επίσης να χειριστούν την ταξινόμηση πολλών τάξεων και μπορούν να χρησιμοποιηθούν τόσο για εποπτευόμενες όσο και για μη εποπτευόμενες μαθησιακές εργασίες.

Ωστόσο, τα δέντρα αποφάσεων μπορεί να υποφέρουν από υπερβολική προσαρμογή, όπου το δέντρο είναι πολύ περίπλοκο και ταιριάζει πολύ κοντά στα δεδομένα εκπαίδευσης, με αποτέλεσμα κακή απόδοση γενίκευσης σε νέα δεδομένα. Αυτό μπορεί να μετριαστεί με τη χρήση τεχνικών κλαδέματος, όπως το κλάδεμα με μειωμένο σφάλμα ή το κλάδεμα με πολυπλοκότητα κόστους [26].

5.3.2 Random Forest

Το Random Forest είναι μια ευρέως χρησιμοποιούμενη μέθοδος εκμάθησης συνόλου στη μηχανική μάθηση που συνδυάζει πολλαπλά δέντρα αποφάσεων για τη βελτίωση της ακρίβειας πρόβλεψης και τη μείωση της υπερπροσαρμογής. Η βασική ιδέα πίσω από το Random Forest είναι να δημιουργηθεί ένας μεγάλος αριθμός δέντρων αποφάσεων χρησιμοποιώντας ένα τυχαίο υποσύνολο των χαρακτηριστικών εισόδου και δειγμάτων δεδομένων και στη συνέχεια να γίνει μέσος όρος των αποτελεσμάτων αυτών των δέντρων για να γίνουν προβλέψεις. Ο αλγόριθμος εισήχθη για πρώτη φορά από τους Leo Breiman και Adele Cutler το 2001.

Το Random Forest λειτουργεί σε δύο στάδια: το στάδιο της εκπαίδευσης και το στάδιο της δοκιμής. Στο στάδιο της εκπαίδευσης, ο αλγόριθμος δημιουργεί ένα δάσος από δέντρα αποφάσεων επιλέγοντας τυχαία ένα υποσύνολο χαρακτηριστικών και δειγμάτων δεδομένων από το σύνολο δεδομένων εισόδου. Κάθε δέντρο απόφασης εκπαιδεύεται σε ένα διαφορετικό υποσύνολο δεδομένων και οι τελικές προβλέψεις λαμβάνονται με τον μέσο όρο των προβλέψεων όλων των δέντρων. Κατά το στάδιο της δοκιμής, νέα δείγματα δεδομένων

⁵ https://en.wikipedia.org/wiki/Decision_tree

περνούν από τα δέντρα απόφασης για να ληφθούν οι προβλέψεις τους, οι οποίες στη συνέχεια υπολογίζονται κατά μέσο όρο για να ληφθεί η τελική πρόβλεψη.


Το κύριο πλεονέκτημα του Random Forest σε σχέση με ένα δέντρο απόφασης είναι η ικανότητά του να μειώνει την υπερπροσαρμογή και να βελτιώνει την απόδοση γενίκευσης. Χτίζοντας έναν μεγάλο αριθμό δέντρων σε τυχαία υποσύνολα δεδομένων, ο αλγόριθμος καταγράφει τις διαφορετικές παραλλαγές και εξαρτήσεις στα δεδομένα και έτσι παρέχει μια πιο ισχυρή και ακριβή πρόβλεψη. Επιπλέον, το Random Forest μπορεί να χειριστεί δεδομένα υψηλών διαστάσεων με μεγάλο αριθμό χαρακτηριστικών και μπορεί επίσης να χειριστεί δεδομένα που λείπουν καταλογίζοντας τις τιμές που λείπουν.

Μία από τις βασικές παραμέτρους στο Random Forest είναι ο αριθμός των δέντρων στο δάσος, ο οποίος είναι μια υπερπαραμέτρος που πρέπει να συντονιστεί με βάση το σύνολο δεδομένων και την επιθυμητή απόδοση. Ο βέλτιστος αριθμός δέντρων εξαρτάται από διάφορους παράγοντες όπως το μέγεθος και η πολυπλοκότητα του συνόλου δεδομένων, ο αριθμός των χαρακτηριστικών εισαγωγής και η επιθυμητή ακρίβεια και ταχύτητα. Συνήθως, ένας μεγάλος αριθμός δέντρων μπορεί να βελτιώσει την ακρίβεια του αλγορίθμου, αλλά με κόστος αυξημένου υπολογιστικού χρόνου και χρήσης μνήμης [26].

5.3.3 Support Vector machines

Οι Υποστήριξη Διανυσματικές Μηχανές (SVM) είναι ένας δημοφιλής τύπος εποπτευόμενου αλγορίθμου εκμάθησης που μπορεί να χρησιμοποιηθεί για ταξινόμηση, παλινδρόμηση και ακόμη και ανίχνευση ακραίων τιμών. Τα SVM βασίζονται στην ιδέα της εύρεσης του καλύτερου δυνατού ορίου απόφασης που διαχωρίζει τα δεδομένα σε διαφορετικές κλάσεις. Το όριο απόφασης ονομάζεται υπερεπίπεδο και τα SVM στοχεύουν να βρουν το υπερεπίπεδο που μεγιστοποιεί το περιθώριο μεταξύ των διαφορετικών κλάσεων. Με άλλα λόγια, τα SVM προσπαθούν να βρουν το υπερεπίπεδο που έχει τη μεγαλύτερη απόσταση από τα πλησιέστερα σημεία δεδομένων κάθε κλάσης.

Ένα από τα πλεονεκτήματα των SVM είναι ότι μπορούν να λειτουργήσουν καλά ακόμα και όταν τα δεδομένα είναι υψηλών διαστάσεων, μη γραμμικά διαχωρισμένα και θορυβώδη. Τα SVM χρησιμοποιούν ένα τέχνασμα πυρήνα για να αντιστοιχίσουν τα δεδομένα εισόδου σε έναν χώρο χαρακτηριστικών υψηλότερης διάστασης όπου είναι πιο πιθανό να είναι γραμμικά διαχωρισμένα. Υπάρχουν διάφοροι τύποι συναρτήσεων πυρήνα, όπως γραμμική, πολυωνυμική, ακτινική συνάρτηση βάσης (RBF) και σιγμοειδής. Η επιλογή της συνάρτησης πυρήνα μπορεί να έχει σημαντικό αντίκτυπο στην απόδοση του SVM και εξαρτάται από το συγκεκριμένο πρόβλημα.



Εικόνα 9: οπτικοποίηση λειτουργίας SVM⁶.


Τα SVM είναι επίσης ανθεκτικά στην υπερβολική προσαρμογή, καθώς προσπαθούν να μεγιστοποιήσουν το περιθώριο μεταξύ των κλάσεων αντί να προσαρμόσουν τα δεδομένα όσο το δυνατόν περισσότερο. Ωστόσο, τα SVM μπορεί να είναι ευαίσθητα στην επιλογή υπερπαραμέτρων, όπως η παράμετρος κανονικοποίησης C και οι παράμετροι του πυρήνα. Στην πράξη, οι υπερπαραμέτροι συνήθως συντονίζονται χρησιμοποιώντας τεχνικές διασταυρούμενης επικύρωσης για την εύρεση των βέλτιστων τιμών [26].

5.3.4 K Nearest Neighbors

Το K-Nearest Neighbor (KNN) είναι ένας απλός αλλά ισχυρός αλγόριθμος μηχανικής μάθησης που μπορεί να χρησιμοποιηθεί τόσο για προβλήματα ταξινόμησης όσο και για προβλήματα παλινδρόμησης. Λειτουργεί βρίσκοντας τον αριθμό k των σημείων δεδομένων εκπαίδευσης που είναι πιο κοντά σε ένα δεδομένο σημείο δεδομένων δοκιμής και ταξινομώντας ή προβλέποντας την ετικέτα του σημείου δεδομένων δοκιμής με βάση τις ετικέτες των k πλησιέστερων γειτόνων του.

Το "k" στο KNN αναφέρεται στον αριθμό των πλησιέστερων γειτόνων που λαμβάνονται υπόψη κατά την ταξινόμηση ή την πρόβλεψη της ετικέτας ενός σημείου δεδομένων δοκιμής. Για παράδειγμα, εάν k=3, τότε ο αλγόριθμος θα βρει τους τρεις πλησιέστερους γείτονες στο σημείο δεδομένων δοκιμής και θα ταξινομήσει ή θα προβλέψει την ετικέτα του με βάση τις ετικέτες αυτών των τριών γειτόνων. Το KNN λειτουργεί με την υπόθεση ότι παρόμοια πράγματα υπάρχουν σε κοντινή απόσταση μεταξύ τους. Επομένως, εάν δύο σημεία δεδομένων είναι κοντά το ένα στο άλλο, είναι πιθανό να ανήκουν στην ίδια κατηγορία ή να έχουν παρόμοιες ετικέτες. Το KNN χρησιμοποιεί μετρήσεις απόστασης όπως η Ευκλείδεια απόσταση ή η απόσταση του Μανχάταν για να μετρήσει την ομοιότητα μεταξύ των σημείων δεδομένων και να βρει τους πλησιέστερους γείτονές τους.

⁶ https://en.wikipedia.org/wiki/Support_vector_machine



Εικόνα 10: οπτικοποίηση λειτουργίας KNN⁷.

Ένα από τα πλεονεκτήματα του KNN είναι ότι είναι ένας μη παραμετρικός αλγόριθμος, που σημαίνει ότι δεν κάνει υποθέσεις σχετικά με την υποκείμενη κατανομή των δεδομένων. Είναι επίσης ένας τεμπέλης αλγόριθμος μάθησης, που σημαίνει ότι δεν μαθαίνει ένα μοντέλο από τα δεδομένα εκπαίδευσης, αλλά αποθηκεύει τα δεδομένα εκπαίδευσης και τα χρησιμοποιεί για ταξινόμηση ή πρόβλεψη κατά τη διάρκεια της δοκιμής.

Το KNN μπορεί να χρησιμοποιηθεί σε ένα ευρύ φάσμα εφαρμογών, όπως συστήματα συστάσεων, ταξινόμηση εικόνων και ανίχνευση ανωμαλιών. Ωστόσο, μπορεί να είναι υπολογιστικά ακριβό και απαιτεί μεγάλη ποσότητα μνήμης για την αποθήκευση των δεδομένων εκπαίδευσης, ειδικά για μεγάλα σύνολα δεδομένων [26]

5.3.5 Xgboost

Ο XGBoost είναι ένας αλγόριθμος μηχανικής εκμάθησης ανοιχτού κώδικα που σχεδιάστηκε για να βελτιώνει την απόδοση του τυπικού αλγόριθμου ενίσχυσης κλίσης. Το XGBoost σημαίνει "EXtreme Gradient Boosting" και είναι μια ισχυρή τεχνική που μπορεί να χρησιμοποιηθεί για εργασίες παλινδρόμησης, ταξινόμησης και κατάταξης. Ο αλγόριθμος βασίζεται σε δέντρα αποφάσεων και χρησιμοποιεί ένα σύνολο δέντρων αποφάσεων για να κάνει προβλέψεις.

Ένα από τα κύρια πλεονεκτήματα του XGBoost είναι η ικανότητά του να χειρίζεται δεδομένα που λείπουν, καθιστώντας τον έναν χρήσιμο αλγόριθμο σε ένα ευρύ φάσμα εφαρμογών. Το XGBoost ενσωματώνει επίσης τεχνικές τακτοποίησης για την αποφυγή υπερβολικής προσαρμογής και τη βελτίωση της απόδοσης γενίκευσης του μοντέλου. Αυτό επιτυγχάνεται προσθέτοντας ποινές στην αντικειμενική συνάρτηση που ο αλγόριθμος προσπαθεί να ελαχιστοποιήσει. Ο αλγόριθμος XGBoost λειτουργεί προσθέτοντας επαναληπτικά δέντρα αποφάσεων στο σύνολο, με κάθε δέντρο να προσπαθεί να διορθώσει τα σφάλματα που έγιναν από το προηγούμενο δέντρο. Ο αλγόριθμος χρησιμοποιεί μια μέθοδο βελτιστοποίησης gradient descent για να εκπαιδεύσει τα δέντρα απόφασης, η οποία περιλαμβάνει τον υπολογισμό της κλίσης της αντικειμενικής συνάρτησης σε σχέση με τις παραμέτρους του μοντέλου.

⁷ https://en.wikipedia.org/wiki/K-nearest_neighbors_algorithm

Για να αποφευχθεί η υπερβολική προσαρμογή, το XGBoost χρησιμοποιεί μια τεχνική που ονομάζεται συρρίκνωση, η οποία περιλαμβάνει τη μείωση του βάρους κάθε δέντρου στο σύνολο. Μια άλλη τεχνική που χρησιμοποιεί το XGBoost είναι η κατάταξη σπουδαιότητας χαρακτηριστικών, η οποία βοηθά στον εντοπισμό των πιο σημαντικών χαρακτηριστικών στο σύνολο δεδομένων.

Το XGBoost έχει αποδειχθεί ότι αποδίδει καλά σε ένα ευρύ φάσμα εφαρμογών, συμπεριλαμβανομένης της ταξινόμησης εικόνων, της αναγνώρισης ομιλίας και της επεξεργασίας φυσικής γλώσσας. Ο αλγόριθμος έχει επίσης χρησιμοποιηθεί σε αρκετούς διαγωνισμούς μηχανικής μάθησης, όπου έχει επιτύχει κορυφαίες επιδόσεις σε μια ποικιλία συνόλων δεδομένων [27].

Κεφάλαιο 6. Βαθιά Μάθηση και Συνδυασμός Μεθόδων

6.1 Deep Learning

Η βαθιά μάθηση είναι ένα υποσύνολο της μηχανικής μάθησης που επικεντρώνεται στην ανάπτυξη τεχνητών νευρωνικών δικτύων με πολλαπλά επίπεδα. Η προσέγγιση βαθιάς μάθησης περιλαμβάνει την εκπαίδευση νευρωνικών δικτύων για την εκμάθηση πολλαπλών επιπέδων αφαίρεσης και την εξαγωγή σημαντικών χαρακτηριστικών από ακατέργαστα δεδομένα.

Συνηθέστερη εφαρμογή της βαθιάς μηχανικής μάθησης είναι τα συνεκτικά νευρωνικά δίκτυα (CNN). Τα CNN χρησιμοποιούν μια τεχνική που ονομάζεται συνέλιξη για την εξαγωγή χαρακτηριστικών από εικόνες, η οποία τους επιτρέπει να αναγνωρίζουν μοτίβα και δομές που είναι σημαντικές για εργασίες ταξινόμησης. Τα περισσότερα από αυτά, αποτελούνται από πολλαπλά επίπεδα, συμπεριλαμβανομένων των συνελικτικών επιπέδων, των επιπέδων συγκέντρωσης και των πλήρως συνδεδεμένων επιπέδων. Στο συνελικτικό επίπεδο, ένα σύνολο φίλτρων περιστρέφεται πάνω από την εικόνα εισόδου για να δημιουργήσει ένα σύνολο χαρτών χαρακτηριστικών. Στη συνέχεια, το επίπεδο συγκέντρωσης χρησιμοποιείται για τη μείωση του δείγματος των χαρτών χαρακτηριστικών, μειώνοντας τη διάσταση της εισόδου. Τέλος, το πλήρως συνδεδεμένο επίπεδο χρησιμοποιείται για να κάνει προβλέψεις με βάση τα εξαγόμενα χαρακτηριστικά.

Επομένως η βαθιά μάθηση επιτρέπει στα δίκτυα είναι ικανά να μαθαίνουν ιεραρχικές αναπαραστάσεις δεδομένων, όπου κάθε επίπεδο του δικτύου μαθαίνει να αναγνωρίζει πιο πολύπλοκα χαρακτηριστικά από το προηγούμενο επίπεδο. Αυτή η ιδιότητα τα καθιστά κατάλληλα για εργασίες όπως ταξινόμηση εικόνων, ανίχνευση αντικειμένων και τμηματοποίηση εικόνας.

6.2 Νευρωνικά Δίκτυα

Η ανάπτυξη των τεχνητών νευρωνικών δικτύων βασίστηκε στη θεμελιώδη διαφορά μεταξύ του τρόπου με τον οποίο ο ανθρώπινος εγκέφαλος επεξεργάζεται τις πληροφορίες και της αντίστοιχης διαδικασίας σε έναν συμβατικό ψηφιακό υπολογιστή. Ο εγκέφαλος είναι ένα πολύπλοκο σύστημα επεξεργασίας με την ικανότητα να επεξεργάζεται πληροφορίες παράλληλα και μη γραμμικά, σε αντίθεση με έναν υπολογιστή. Μέσω της σωστής οργάνωσης δομικών στοιχείων, όπως οι νευρώνες, ο εγκέφαλος μπορεί να εκτελέσει συγκεκριμένους υπολογισμούς με ιλιγγιώδη ταχύτητα, ξεπερνώντας κατά πολύ αυτόν ακόμη και των υπερσύγχρονων υπολογιστών. Τα νευρωνικά δίκτυα χρησιμοποιούν έναν τεράστιο αριθμό διασυνδεδεμένων υπολογιστικών κυττάρων, που ονομάζονται «νευρώνες» ή «μονάδες επεξεργασίας», για να επιτύχουν υψηλή απόδοση σε εργασίες όπως η αναγνώριση προτύπων, η αντίληψη, ο έλεγχος κίνησης, η ανάλυση ηχητικών κυμάτων, ακόμη και η κατανόηση κειμένου.

Ένα συγκεκριμένο παράδειγμα υπολογισμού νευρωνικών δικτύων είναι η ανθρώπινη όραση. Ο εγκέφαλος επεξεργάζεται συνεχώς νέες οπτικές πληροφορίες που παρέχονται από το

οπτικό σύστημα, το οποίο προσφέρει μια συνεχώς μεταβαλλόμενη αναπαράσταση του περιβάλλοντος, παρέχοντας την απαραίτητη εισαγωγή δεδομένων για εργασίες αναγνώρισης. Τα τεχνητά νευρωνικά δίκτυα μοιάζουν πολύ με τον ανθρώπινο εγκέφαλο, καθώς αποκτούν γνώση από το περιβάλλον τους μέσω μιας διαδικασίας μάθησης και την αποθηκεύουν χρησιμοποιώντας τη δύναμη των συνδέσεων μεταξύ των νευρώνων, που ονομάζεται συναπτικό βάρος.

Ένα τεχνητό νευρωνικό δίκτυο ορίζεται ως ένας μαζικά παράλληλος επεξεργαστής με κατανεμημένη αρχιτεκτονική, που αποτελείται από απλές μονάδες επεξεργασίας με την εγγενή ικανότητα αποθήκευσης εμπειρικής γνώσης και διάθεσης για χρήση. Ο αλγόριθμος εκμάθησης τροποποιεί τα συναπτικά βάρη του δικτύου για την επίτευξη του επιθυμητού στόχου. Ο αλγόριθμος εκμάθησης είναι ένα κρίσιμο στοιχείο των νευρωνικών δικτύων, καθώς είναι υπεύθυνος για την τροποποίηση των συναπτικών βαρών στο δίκτυο, επηρεάζοντας τελικά την ικανότητα του δικτύου να επεξεργάζεται πληροφορίες με ακρίβεια.

Υπάρχουν διάφοροι τύποι νευρωνικών δικτύων, όπως δίκτυα προώθησης, επαναλαμβανόμενα δίκτυα και συνελκτικά δίκτυα, το καθένα σχεδιασμένο για συγκεκριμένες εφαρμογές. Τα δίκτυα ανατροφοδότησης χρησιμοποιούν μια διαδοχική ροή πληροφοριών μέσω στρωμάτων νευρώνων, ενώ τα επαναλαμβανόμενα δίκτυα χρησιμοποιούν βρόχους ανάδρασης για να επιτρέψουν την επεξεργασία των χρονικών δεδομένων. Τα συνελκτικά δίκτυα είναι ιδιαίτερα χρήσιμα για την επεξεργασία εικόνας, με μια μοναδική αρχιτεκτονική βελτιστοποιημένη για το χειρισμό δισδιάστατων δεδομένων.

Η δημοτικότητα των νευρωνικών δικτύων έχει αυξηθεί τα τελευταία χρόνια, λόγω της προόδου στην υπολογιστική ισχύ και των τεράστιων ποσοτήτων δεδομένων που είναι διαθέσιμα για εκπαίδευση. Η ικανότητα χρήσης νευρωνικών δικτύων για πολύπλοκες εργασίες, όπως η επεξεργασία φυσικής γλώσσας, η αναγνώριση εικόνας, ακόμη και η αναπαραγωγή παιχνιδιών, έχει φέρει επανάσταση στον τομέα της τεχνητής νοημοσύνης. Με συνεχή έρευνα και ανάπτυξη, τα νευρωνικά δίκτυα έχουν τη δυνατότητα να ξεκλειδώσουν νέες εφαρμογές σε διάφορους τομείς, όπως η ιατρική, η χρηματοδότηση και οι μεταφορές.

6.2.1 Ιδιότητες νευρωνικών δικτύων

Τα νευρωνικά δίκτυα είναι ένας τύπος μηχανικής μάθησης που διαμορφώνεται σύμφωνα με τον ανθρώπινο εγκέφαλο. Αποτελούνται από διασυνδεδεμένους κόμβους, που ονομάζονται νευρώνες, οι οποίοι επεξεργάζονται πληροφορίες και οργανώνονται σε επίπεδα. Ακολουθούν μερικές από τις ιδιότητες των νευρωνικών δικτύων:

- **Μη γραμμικότητα:** Τα νευρωνικά δίκτυα είναι ικανά για μη γραμμικούς υπολογισμούς, που σημαίνει ότι μπορούν να μοντελοποιήσουν σύνθετες σχέσεις μεταξύ εισόδων και εξόδων που δεν μπορούν να αναπαρασταθούν εύκολα χρησιμοποιώντας παραδοσιακές γραμμικές μεθόδους. Για παράδειγμα, ένα νευρωνικό δίκτυο μπορεί να προβλέψει με ακρίβεια την τιμή ενός σπιτιού με βάση το μέγεθος, την τοποθεσία του και άλλα χαρακτηριστικά, ακόμα κι αν η σχέση μεταξύ αυτών των παραγόντων δεν είναι γραμμική.
- **Αντιστοίχιση εισόδου-εξόδου:** Τα νευρωνικά δίκτυα μαθαίνουν να χαρτογραφούν εισόδους σε εξόδους προσαρμόζοντας τα βάρη των συνδέσεων μεταξύ των

νευρώνων. Αυτό τους επιτρέπει να εκτελούν εργασίες όπως η αναγνώριση εικόνας, η αναγνώριση ομιλίας και η μετάφραση γλώσσας.

- Προσαρμοστικότητα: Τα νευρωνικά δίκτυα είναι σε θέση να προσαρμόζονται και να μαθαίνουν από νέα δεδομένα, γεγονός που τα καθιστά χρήσιμα σε εφαρμογές όπου τα δεδομένα εισόδου αλλάζουν συνεχώς. Για παράδειγμα, ένα νευρωνικό δίκτυο μπορεί να μάθει να αναγνωρίζει νέα πρόσωπα καθώς προστίθενται σε μια βάση δεδομένων.
- Ενδεικτική απόκριση: Τα νευρωνικά δίκτυα μπορούν να παρέχουν έναν βαθμό εμπιστοσύνης στην έξοδο τους, επιτρέποντάς τους να υποδείξουν το επίπεδο αβεβαιότητας ή ασάφειας στην πρόβλεψή τους. Αυτό είναι χρήσιμο σε εφαρμογές όπως η ιατρική διάγνωση, όπου ένα νευρωνικό δίκτυο μπορεί να υποδείξει την πιθανότητα μιας ασθένειας με βάση τα συμπτώματα του ασθενούς.
- Πληροφορίες σχετικές με το περιεχόμενο: Τα νευρωνικά δίκτυα είναι σε θέση να εξάγουν και να χρησιμοποιούν σχετικές πληροφορίες από μεγάλα και πολύπλοκα σύνολα δεδομένων. Για παράδειγμα, ένα νευρωνικό δίκτυο εκπαιδευμένο σε ένα μεγάλο σύνολο δεδομένων εικόνων μπορεί να εξάγει χαρακτηριστικά όπως άκρες, σχήματα και χρώματα και να χρησιμοποιήσει αυτές τις πληροφορίες για να ταξινομήσει με ακρίβεια νέες εικόνες.
- Ανοχή σφαλμάτων: Τα νευρωνικά δίκτυα είναι σε θέση να ανέχονται σφάλματα ή δεδομένα που λείπουν στην είσοδο χωρίς να επηρεάζουν σημαντικά την απόδοσή τους. Αυτό συμβαίνει επειδή οι πληροφορίες κατανέμονται σε πολλούς νευρώνες, αντί να βασίζονται σε μία μόνο είσοδο.
- Δυνατότητα εφαρμογής VLSI: Τα νευρωνικά δίκτυα μπορούν να υλοποιηθούν σε υλικό, όπως ολοκληρωμένα κυκλώματα για συγκεκριμένες εφαρμογές (ASIC), για επεξεργασία υψηλής ταχύτητας και χαμηλής ισχύος.
- Ανάλυση και ομοιομορφία σχεδίασης: Τα νευρωνικά δίκτυα μπορούν να αναλυθούν και να σχεδιαστούν χρησιμοποιώντας ένα κοινό σύνολο μαθηματικών τεχνικών, το οποίο επιτρέπει την εύκολη σύγκριση και βελτιστοποίηση διαφορετικών αρχιτεκτονικών δικτύων.
- Αναλογία με τη νευροφυσιολογία του εγκεφάλου: Τα νευρωνικά δίκτυα εμπνέονται από τη δομή και τη λειτουργία του ανθρώπινου εγκεφάλου, γεγονός που τα καθιστά σημαντικό εργαλείο για τη μελέτη της εγκεφαλικής λειτουργίας και την ανάπτυξη θεραπειών για νευρολογικές διαταραχές.

Συνολικά, οι ιδιότητες των νευρωνικών δικτύων τα καθιστούν εξαιρετικά αποτελεσματικά και ευέλικτα εργαλεία για ένα ευρύ φάσμα εφαρμογών σε τομείς όπως η όραση υπολογιστών, η επεξεργασία φυσικής γλώσσας και η ρομποτική. Με τις συνεχείς προόδους στην τεχνολογία και την έρευνα, τα νευρωνικά δίκτυα είναι πιθανό να διαδραματίζουν ολοένα και πιο σημαντικό ρόλο στη διαμόρφωση του μέλλοντος της τεχνητής νοημοσύνης και της μηχανικής μάθησης [26].


6.2.2 Τύποι συνάρτησης ενεργοποίησης

Τα νευρωνικά δίκτυα χρησιμοποιούν συναρτήσεις ενεργοποίησης, οι οποίες καθορίζουν την έξοδο ενός νευρώνα με δεδομένη μια είσοδο ή ένα σύνολο εισόδων. Μια συνάρτηση

ενεργοποίησης μπορεί να θεωρηθεί ως μια διαδικασία λήψης αποφάσεων που προσθέτει μη γραμμικότητα στο δίκτυο, επιτρέποντάς του να μοντελοποιεί περίπλοκες σχέσεις μεταξύ εισόδων και εξόδων.

Μια κοινή συνάρτηση ενεργοποίησης είναι η συνάρτηση σιγμοειδούς, η οποία λαμβάνει οποιαδήποτε τιμή εισόδου και εξάγει μια τιμή μεταξύ 0 και 1. Αυτό την καθιστά χρήσιμη για εργασίες δυαδικής ταξινόμησης, όπου το δίκτυο πρέπει να εξάγει είτε 0 είτε 1. Η συνάρτηση σιγμοειδούς χρησιμοποιείται επίσης σε επαναλαμβανόμενα νευρωνικά δίκτυα, τα οποία μπορούν να μοντελοποιήσουν ακολουθίες εισόδων και εξόδων με την πάροδο του χρόνου. Μια άλλη δημοφιλής λειτουργία ενεργοποίησης είναι η λειτουργία ReLU, η οποία σημαίνει Διορθωμένη Γραμμική Μονάδα. Αυτή η συνάρτηση παίρνει μια τιμή εισόδου και βγάζει 0 εάν η είσοδος είναι αρνητική ή την ίδια την τιμή εισόδου εάν είναι θετική. Το ReLU χρησιμοποιείται συνήθως στη βαθιά μάθηση επειδή είναι υπολογιστικά αποδοτικό και έχει αποδειχθεί ότι οδηγεί σε καλύτερη απόδοση από άλλες λειτουργίες ενεργοποίησης όπως το σιγμοειδές ή το Tanh. Στην εικόνα 11 παρατίθενται 9 από τις πιο δημοφιλείς συναντήσεις ενεργοποίησης καθώς και οι γραφικές τους παραστάσεις.

Εκτός από αυτές τις κοινώς χρησιμοποιούμενες λειτουργίες ενεργοποίησης, υπάρχουν και άλλες λειτουργίες που μπορούν να χρησιμοποιηθούν σε συγκεκριμένες καταστάσεις. Για παράδειγμα, η συνάρτηση softmax χρησιμοποιείται σε εργασίες ταξινόμησης πολλαπλών κλάσεων, όπου το δίκτυο πρέπει να εξάγει μια κατανομή πιθανότητας σε πολλαπλές κλάσεις. Αξίζει να σημειωθεί ότι η επιλογή της συνάρτησης ενεργοποίησης μπορεί να έχει σημαντικό αντίκτυπο στην απόδοση ενός νευρωνικού δικτύου και η επιλογή της κατάλληλης συνάρτησης για μια δεδομένη εργασία είναι ένα σημαντικό μέρος του σχεδιασμού και της εκπαίδευσης του δικτύου.



Εικόνα 11: Γραφικές παραστάσεις συναρτήσεων ενεργοποίησης⁸.

Επιπλέον, υπάρχουν επίσης τεχνικές όπως η ομαλοποίηση παρτίδας και η εγκατάλειψη που μπορούν να χρησιμοποιηθούν για τη βελτίωση της απόδοσης των λειτουργιών ενεργοποίησης. Η ομαλοποίηση παρτίδας χρησιμοποιείται για την κανονικοποίηση των εισόδων σε έναν νευρώνα, κάτι που μπορεί να βοηθήσει στη μείωση των επιπτώσεων των διαβαθμίσεων που εξαφανίζονται και στην επιτάχυνση της διαδικασίας εκπαίδευσης. Το Dropout είναι μια τεχνική τακτοποίησης που αποβάλλει τυχαία ένα ορισμένο ποσοστό

⁸ <https://www.v7labs.com/blog/neural-networks-activation-functions>

νευρώνων κατά τη διάρκεια της προπόνησης, κάτι που μπορεί να βοηθήσει στην πρόληψη της υπερβολικής προσαρμογής και στη βελτίωση της γενίκευσης [26].


6.3 CNNs

Τα συνελκτικά νευρωνικά δίκτυα (CNN) είναι ένας τύπος αρχιτεκτονικής νευρωνικών δικτύων που έχει σχεδιαστεί ειδικά για την επεξεργασία δεδομένων εικόνας και βίντεο. Σε αντίθεση με άλλα νευρωνικά δίκτυα, τα οποία δέχονται μια ισοπεδωμένη είσοδο σταθερού μεγέθους, τα CNN λαμβάνουν μια είσοδο ακατέργαστων pixel εικόνας και μαθαίνουν να εξάγουν σχετικά χαρακτηριστικά μέσω συνελκτικών επιπέδων.

Τα CNN βασίζονται σε μια λειτουργία συνέλιξης, η οποία περιλαμβάνει την ολίσθηση ενός μικρού φίλτρου, γνωστό και ως πυρήνας ή ανιχνευτή χαρακτηριστικών, κατά μήκος της εικόνας σε μια σειρά βημάτων. Το φίλτρο εκτελεί πολλαπλασιασμό βάσει στοιχείων με τα εικονοστοιχεία εισόδου με τα οποία επικαλύπτεται και, στη συνέχεια, αθροίζει τις προκύπτουσες τιμές για να παράγει ένα μόνο εικονοστοιχείο εξόδου στον χάρτη χαρακτηριστικών. Αυτή η διαδικασία επαναλαμβάνεται σε ολόκληρη την εικόνα για να δημιουργηθεί ένας πλήρης χάρτης χαρακτηριστικών και οπτικοποιείται και στην εικόνα 12 όπως φαίνεται παρακάτω.

Μέσω αυτής της διαδικασίας, το CNN μπορεί να μάθει να αναγνωρίζει διαφορετικά χαρακτηριστικά μιας εικόνας, όπως άκρες, υφές και σχήματα. Τα φίλτρα στα πρώτα επίπεδα ενός CNN τείνουν να αναγνωρίζουν απλά χαρακτηριστικά όπως γραμμές και καμπύλες, ενώ τα βαθύτερα στρώματα μπορεί να μάθουν να αναγνωρίζουν πιο σύνθετα χαρακτηριστικά όπως χαρακτηριστικά προσώπου ή σχήματα αντικειμένων.

Μόλις εξαχθούν τα σχετικά χαρακτηριστικά από την εικόνα εισόδου, στη συνέχεια περνούν μέσα από ένα ή περισσότερα πλήρως συνδεδεμένα στρώματα, γνωστά και ως πυκνά στρώματα, τα οποία λειτουργούν ως παραδοσιακό νευρωνικό δίκτυο για την πρόβλεψη της εξόδου. Η έξοδος των πυκνών στρωμάτων μπορεί να είναι δυαδική, πολλών κλάσεων (multiclass) ή παλινδρόμηση, ανάλογα με την εργασία που εκτελείται.



Εικόνα 12 : Γραφικές παραστάσεις συναρτήσεων ενεργοποίησης⁹

Ένα από τα βασικά πλεονεκτήματα των CNN είναι η ικανότητά τους να μαθαίνουν τη χωρική αμετάβλητη, που σημαίνει ότι μπορούν να αναγνωρίσουν αντικείμενα ανεξάρτητα από τη

⁹ <https://developersbreach.com/convolution-neural-network-deep-learning/>

θέση ή τον προσανατολισμό τους στην εικόνα. Αυτό επιτυγχάνεται μέσω των στρωμάτων συγκέντρωσης, τα οποία μειώνουν τις χωρικές διαστάσεις των χαρτών χαρακτηριστικών, ενώ διατηρούν τις πιο σημαντικές πληροφορίες.

Ένα άλλο πλεονέκτημα των CNN είναι η ικανότητά τους να εκτελούν επαύξηση δεδομένων, η οποία περιλαμβάνει την εφαρμογή τυχαίων μετασχηματισμών στις εικόνες εισόδου κατά τη διάρκεια της εκπαίδευσης για να αυξηθεί το μέγεθος του συνόλου δεδομένων και να αποφευχθεί η υπερβολική προσαρμογή. Οι κοινές τεχνικές αύξησης δεδομένων περιλαμβάνουν την τυχαία περικοπή, την αναστροφή και την περιστροφή.

Τα CNN έχουν γίνει όλο και πιο δημοφιλή τα τελευταία χρόνια λόγω της υψηλής ακρίβειας και της ικανότητάς τους να μαθαίνουν πολύπλοκα χαρακτηριστικά από μεγάλα σύνολα δεδομένων. Έχουν εφαρμοστεί με επιτυχία σε ένα ευρύ φάσμα εργασιών όρασης υπολογιστή, όπως ταξινόμηση εικόνων, ανίχνευση αντικειμένων και σημασιολογική τμηματοποίηση [28].

Μια δημοφιλή οικογένεια συνελκτικών νευρωνικών δικτύων (CNN) αποτελούν τα EfficientNet [29], σχεδιασμένα με στόχο την επίτευξη υπερσύγχρονης ακρίβειας χρησιμοποιώντας λιγότερους υπολογιστικούς πόρους από τα προηγούμενα μοντέλα¹⁰. Αυτά τα δίκτυα αναπτύχθηκαν με την κλιμάκωση της αρχιτεκτονικής με συστηματικό και αποτελεσματικό τρόπο, ενσωματώνοντας τις πρόσφατες εξελίξεις στην έρευνα της αρχιτεκτονικής νευρωνικών δικτύων.

Τα μοντέλα EfficientNet αποτελούνται από πολλαπλά επίπεδα συνέλιξης, ακολουθούμενα από λειτουργίες ομαλοποίησης παρτίδας και ενεργοποίησης [29]. Αυτά τα στρώματα σχηματίζουν ένα στάδιο εξαγωγής χαρακτηριστικών, το οποίο στη συνέχεια ακολουθείται από ένα στάδιο ταξινόμησης, που συνήθως αποτελείται από ένα ή περισσότερα πλήρως συνδεδεμένα στρώματα. Το στάδιο εξαγωγής χαρακτηριστικών έχει σχεδιαστεί για να μαθαίνει αφηρημένες και ιεραρχικές αναπαραστάσεις των δεδομένων εισόδου, ενώ το στάδιο ταξινόμησης αντιστοιχίζει αυτές τις αναπαραστάσεις στις επιθυμητές ετικέτες εξόδου.

Όσον αφορά τις εφαρμογές, το EfficientNet έχει χρησιμοποιηθεί σε ένα ευρύ φάσμα εργασιών όρασης υπολογιστή, όπως ταξινόμηση εικόνων, ανίχνευση αντικειμένων και σημασιολογική τμηματοποίηση. Έχει επιτύχει κορυφαίες επιδόσεις σε πολλά σημεία αναφοράς, συμπεριλαμβανομένου του ImageNet Large Scale Visual Recognition Challenge (ILSVRC) και της πρόκλησης ανίχνευσης Common Objects in Context (COCO).

Σε ίδιο με πριν δυο ακόμα δημοφιλείς οικογένειες είναι αυτές του ResNet και του MobileNet που έχουν κερδίσει σημαντική προσοχή στον τομέα της όρασης υπολογιστών και των εργασιών αναγνώρισης εικόνας. Το ResNet, συντομογραφία του Residual Network, εισήγαγε μια νέα προσέγγιση για την αντιμετώπιση της πρόκλησης της εκπαίδευσης σε βαθιά νευρωνικά δίκτυα. Χρησιμοποιούσε συνδέσεις παράλειψης ή συντομεύσεις που επέτρεπαν στο δίκτυο να μάθει υπολειπόμενες αντιστοιχίσεις, επιτρέποντας την εκπαίδευση πολύ βαθύτερων αρχιτεκτονικών με βελτιωμένη ακρίβει¹¹. Από την άλλη πλευρά, το MobileNet σχεδιάστηκε ειδικά για τη βελτιστοποίηση της υπολογιστικής απόδοσης και του μεγέθους του μοντέλου για κινητές συσκευές και ενσωματωμένες συσκευές. Εισήγαγε διαχωρίσιμες

¹⁰ <https://keras.io/api/applications/efficientnet>

¹¹ <https://hasty.ai/docs/mp-wiki/model-architectures/resnet>

συνελίξεις κατά βάθος, οι οποίες μείωσαν σημαντικά τον αριθμό των παραμέτρων και των υπολογισμών που απαιτούνται σε σύγκριση με τα παραδοσιακά συνελικτικά στρώματα¹².

Τόσο το ResNet όσο και το MobileNet έχουν συμβάλει σημαντικά στην προώθηση των δυνατοτήτων των CNN. Έχουν γίνει δημοφιλείς επιλογές για διάφορες εργασίες όρασης υπολογιστή λόγω της ικανότητάς τους να καταγράφουν αποτελεσματικά και να εξάγουν περίπλοκα χαρακτηριστικά από εικόνες, οδηγώντας σε ακριβείς προβλέψεις.

6.5 CNN and traditional Machine learning fusion algorithms

Η φιλοσοφία πίσω από τον συνδυασμό πολλαπλών μεθόδων μηχανικής μάθησης είναι να εκμεταλλευόμαστε τα μοναδικά δυνατά σημεία κάθε μεθόδου, αντισταθμίζοντας παράλληλα τις μεμονωμένες αδυναμίες τους. Συνδυάζοντας πολλαπλές μεθόδους, μπορούμε να δημιουργήσουμε ένα πιο ισχυρό και ακριβές μοντέλο από αυτό που θα ήταν δυνατό με οποιαδήποτε μεμονωμένη μέθοδο.

Στην περίπτωση που εξετάζεται στην συγκριμένη έρευνα, θα μελετηθεί ο συνδυασμός ενός συνελικτικού νευρωνικού δικτύου (CNN) όπως το EfficientNet μαζί με άλλες μεθόδους, όπως μηχανές διανυσμάτων υποστήριξης (SVM), K-πλησιέστεροι γείτονες (KNN) και XGBoost. Η εκτέλεση πραγματοποιείται εξάγοντας χαρακτηριστικά με την χρήση των CNNs από τις εικόνες και στην συνέχεια συνδυάζοντας τα με την πληροφορία που παράχθηκε από την βιβλιοθήκη της *pyradiomics*. Αυτό μπορεί να βοηθήσει στη βελτίωση της ακρίβειας και της γενίκευσης του μοντέλου, καθώς και να το καταστήσει πιο ερμηνεύσιμο και διαφανές.

Το CNN είναι ιδιαίτερα χρήσιμο για δεδομένα που βασίζονται σε εικόνες, καθώς μπορεί αυτόματα να μάθει πολύπλοκα μοτίβα και σχέσεις στα δεδομένα που μπορεί να είναι δύσκολο ή αδύνατο να διακρίνει ο άνθρωπος. Χρησιμοποιώντας ένα προεκπαιδευμένο CNN όπως το EfficientNet, μπορούμε να εκμεταλλευτούμε την τεχνογνωσία και τους υπολογιστικούς πόρους που έχουν χρησιμοποιηθεί για την εκπαίδευση του μοντέλου σε ένα μεγάλο σύνολο δεδομένων και να το εφαρμόσουμε στο δικό μας συγκεκριμένο πρόβλημα.

Οι μέθοδοι SVM, KNN και XGBoost είναι όλες παραδείγματα «παραδοσιακών» αλγορίθμων μηχανικής μάθησης που μπορούν να χρησιμοποιηθούν για εργασίες ταξινόμησης. Τα SVM είναι ιδιαίτερα χρήσιμα για προβλήματα δυαδικής ταξινόμησης όπου τα δεδομένα μπορεί να είναι μη-γραμμικώς διαχωρίσιμα, ενώ το KNN μπορεί να είναι αποτελεσματικό για μικρά σύνολα δεδομένων με σαφή δομή. Το XGBoost είναι μια μέθοδος συνόλου που βασίζεται σε δέντρα που μπορεί να είναι αποτελεσματική για ένα ευρύ φάσμα συνόλων δεδομένων και προβλημάτων.


Συνδυάζοντας τα χαρακτηριστικά που εξάγει το CNN με τις προβλέψεις αυτών των άλλων μεθόδων, μπορούμε να δημιουργήσουμε ένα πιο ακριβές και ισχυρό μοντέλο από οποιαδήποτε μεμονωμένη μέθοδο. Το CNN βοηθά στην καταγραφή των πολύπλοκων μοτίβων στα δεδομένα, ενώ οι άλλες μέθοδοι βοηθούν στη βελτίωση και ερμηνεία αυτών των μοτίβων με τρόπο που να είναι εύκολα κατανοητοί και να εφαρμοστούν.

¹² https://wiki.sipeed.com/ai/en/nn_models/mobilenet.html

6.6 Παραδείγματα και εφαρμογές γύρω από των τον συνδυασμό μεθόδων στην μηχανική μάθηση

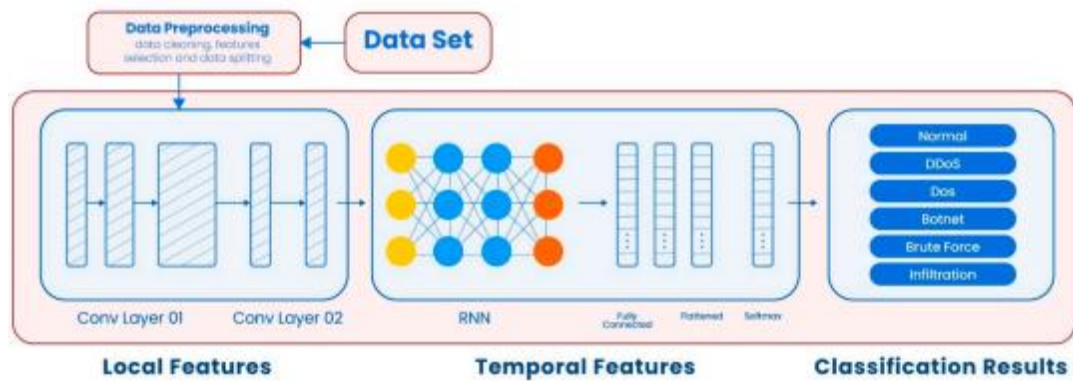
Η επιστημονική κοινότητα έχει δείξει μεγάλο ενδιαφέρον για την ανάπτυξη συνδυαστικών μοντέλων που αξιοποιούν τα δυνατά σημεία διαφορετικών αλγορίθμων μηχανικής μάθησης. Αυτή η ερευνητική φιλοσοφία αποτέλεσε το επίκεντρο αυτής της διατριβής, όπου διάφοροι συνδυασμοί, συμπεριλαμβανομένων αυτών που διερευνήθηκαν, έχουν διερευνηθεί διεξοδικά για την αξιολόγηση της αποτελεσματικότητάς τους. Συνδυάζοντας πολλαπλούς αλγόριθμους μηχανικής μάθησης, οι ερευνητές στοχεύουν να αξιοποιήσουν τα μοναδικά πλεονεκτήματα κάθε προσέγγισης και να επιτύχουν βελτιωμένη απόδοση στην αντιμετώπιση σύνθετων προβλημάτων. Αυτή η προσέγγιση επιτρέπει την ενοποίηση διαφορετικών μεθοδολογιών, ενισχύοντας τη συνολική ικανότητα του μοντέλου και επεκτείνοντας τις πιθανές εφαρμογές του. Κάποιες από τις μελέτες που διερευνούν τον ανωτέρω ισχυρισμό παρατίθενται παρακάτω.

Αρχικά, Η εργασία με τίτλο "Hybrid convolutional neural networks with SVM classifier for classification of skin cancer " από την Duggani et al [30] εστιάζει στην ανάπτυξη ενός υβριδικού μοντέλου για την ταξινόμηση του καρκίνου του δέρματος. Η αρχιτεκτονική του υβριδικού μοντέλου που περιγράφεται περιλαμβάνει τη χρήση CNN ως εξαγωγέα χαρακτηριστικών για την καταγραφή σημαντικών μοτίβων και χαρακτηριστικών από εικόνες καρκίνου του δέρματος. Τα εξαγόμενα χαρακτηριστικά στη συνέχεια τροφοδοτούνται σε ταξινομητές SVM, KNN και DT για την τελική εργασία ταξινόμησης (Εικόνα 13). Το αποτέλεσμα τις συνδυαστικής μεθόδου παρουσιάζουν μικρή βελτίωση στην απόδοση των μοντέλων [30] .



Εικόνα 13: Παράδειγμα συνδυαστικής μεθόδου[30]

Εν συνέχεια, σε μια αντίστοιχη έρευνα ο E.U.H. Qazi πραγματεύεται την κρίσιμη ανάγκη για αποτελεσματικά συστήματα ανίχνευσης εισβολής (IDS) στην εποχή των αυξανόμενων κυβερνοεπιθέσεων [31]. Οι συγγραφείς συζητούν διαφορετικές κατηγορίες IDS με βάση την ανάλυση συμπεριφοράς δικτύου, την ανάλυση υπογραφών διακομιστή και τις υβριδικές προσεγγίσεις που συνδυάζουν μεθόδους ανίχνευσης ανωμαλιών και υπογραφών. Συγκεκριμένα, οι συγγραφείς επικεντρώνονται σε τεχνικές εκμάθησης συνόλου (EL) που συνδυάζουν πολλαπλά μοντέλα σε ένα ενοποιημένο σύστημα για βελτιωμένη ανίχνευση (Εικόνα 14). Οι συγγραφείς προτείνουν ένα βελτιωμένο μοντέλο βαθιάς νευρωνικού δικτύου που συνδυάζει αρχιτεκτονικές επαναλαμβανόμενου νευρωνικού δικτύου (RNN) και συνεκτικού νευρωνικού δικτύου (CNN) για την αποτελεσματική ανίχνευση και ταξινόμηση της κακόβουλης κίνησης δικτύου [31].



Εικόνα 14: Παράδειγμα συνδυαστικής μεθόδου (2) [31]

Τέλος , μια ακόμα μελέτη το ίδιο πλαίσιο με τίτλο «Mitosis detection in breast cancer pathology images by combining handcrafted and convolutional neural network features» εστιάζει στην ανίχνευση μιτωτικών μορφών σε εικόνες παθολογίας του καρκίνου του μαστού. Η μελέτη στοχεύει να βελτιώσει την ακρίβεια της ανίχνευσης μίτωσης συνδυάζοντας χειροποίητα χαρακτηριστικά με χαρακτηριστικά που εξάγονται από συνελκτικά νευρωνικά δίκτυα (CNN). Οι συγγραφείς της εργασίας προτείνουν μια υβριδική προσέγγιση που συνδυάζει παραδοσιακά χειροποίητα χαρακτηριστικά, τα οποία έχουν σχεδιαστεί χειροκίνητα για να καταγράψουν συγκεκριμένα χαρακτηριστικά μιτωτικών μορφών, με χαρακτηριστικά που μαθαίνονται από CNN, τα οποία είναι ικανά να εξάγουν αυτόματα σχετικά χαρακτηριστικά από τις εικόνες [32].

Κεφάλαιο 7. Μεθοδολογία

7.1 Εισαγωγή

Ο πρωταρχικός στόχος αυτής της διατριβής είναι να διερευνήσει και να αξιολογήσει διάφορες προσεγγίσεις και αλγόριθμους μηχανικής μάθησης με στόχο την ακριβή ταξινόμηση των περιστατικών δερματίτιδας χρησιμοποιώντας τα δεδομένα που συλλέχθηκαν στην πειραματική διαδικασία. Η ταξινόμηση των περιπτώσεων δερματίτιδας είναι ένα κρίσιμο έργο στην ιατρική διάγνωση και η χρήση τεχνικών μηχανικής μάθησης μπορεί να προσφέρει πολύτιμες γνώσεις και ενδεχομένως να βελτιώσει την ακρίβεια της διαδικασίας ταξινόμησης.

Μετά από μια αρχική εξερεύνηση και οπτικοποίηση των εικόνων εισόδου, ήταν προφανές ότι ορισμένα βήματα προεπεξεργασίας ήταν απαραίτητα πριν από την εφαρμογή αλγορίθμων μηχανικής εκμάθησης. Αυτά τα βήματα περιελάμβαναν την αφαίρεση των ακραίων τιμών και την κανονικοποίηση των δεδομένων. Αυτή η προεπεξεργασία είναι ζωτικής σημασίας για τους αλγόριθμους μηχανικής μάθησης, καθώς διασφαλίζει ότι τα δεδομένα είναι σε συνεπή και τυποποιημένη μορφή, η οποία βοηθά στην επίτευξη βέλτιστης απόδοσης. Οι ακραίες τιμές μπορούν να επηρεάσουν σημαντικά τη διαδικασία μάθησης και να παραμορφώσουν τα αποτελέσματα, ενώ η κανονικοποίηση βοηθά στην κλιμάκωση των δεδομένων και στη βελτίωση της σύγκλισης κατά τη διάρκεια της εκπαίδευσης.

Η μεθοδολογία περιλάμβανε τη διεξαγωγή τριών πειραμάτων για την αξιολόγηση διαφορετικών προσεγγίσεων για την ανίχνευση δερματίτιδας. Το πρώτο πείραμα επικεντρώθηκε σε παραδοσιακούς αλγόριθμους μηχανικής μάθησης, συμπεριλαμβανομένων των Decision Tree, Random Forest, Support Vector Machines, Nearest Neighbors και XGBoost. Αυτοί οι αλγόριθμοι επιλέχθηκαν με βάση την καθιερωμένη αποτελεσματικότητά τους στις εργασίες ταξινόμησης. Το δεύτερο πείραμα αφορούσε τη χρήση Συνελκτικών Νευρωνικών Δικτύων (CNN) όπως το EfficientNet, το ResNet και το MobileNet. Τα CNN είναι ιδιαίτερα κατάλληλα για εργασίες ανάλυσης εικόνας λόγω της ικανότητάς τους να εξάγουν περίπλοκα χαρακτηριστικά και μοτίβα από εικόνες. Αυτό το πείραμα είχε ως στόχο να αξιολογήσει την απόδοση των μοντέλων βαθιάς μάθησης στην ανίχνευση δερματίτιδας. Τέλος, πραγματοποιήθηκε η συγχώνευση του πρώτου και του δεύτερου πειράματος. Αυτό συνεπαγόταν το συνδυασμό των πλεονεκτημάτων των παραδοσιακών αλγορίθμων μηχανικής μάθησης και των CNN για την αξιοποίηση των συμπληρωματικών δυνατοτήτων τους. Με την ενσωμάτωση των αποτελεσμάτων και των δύο προσεγγίσεων, ο στόχος ήταν να επιτευχθεί δυναμικά βελτιωμένη απόδοση και ακρίβεια.


Για την αξιολόγηση της αποτελεσματικότητας των διαφορετικών μοντέλων, υπολογίστηκαν διάφορες μετρικές. Μεταξύ αυτών των μετρήσεων, η βαθμολογία της F1 έπαιξε κρίσιμο ρόλο. Η βαθμολογία F1 παρέχει μια ολοκληρωμένη αξιολόγηση της απόδοσης του μοντέλου, λαμβάνοντας υπόψη τόσο τα ψευδώς θετικά όσο και τα ψευδώς αρνητικά, τα οποία είναι ιδιαίτερα σημαντικά στην ανίχνευση δερματίτιδας.

7.2 Διαχωρισμός δεδομένων


Όπως αναφέρθηκε στο Κεφάλαιο 2 από την προαναφερθείσα πειραματική διαδικασία συγκεντρώθηκε σύνολο δεδομένων το οποίο θα χρησιμοποιηθεί για την εκπαίδευση μοντέλων μηχανικής μάθησης. Κατά την διάρκεια των πειραμάτων όπως προέκυψε λόγω των περιορισμένων δεδομένων το πρόβλημα ανάχθηκε σε δυαδικό. Αυτό σημαίνει ότι παρακάτω ερευνητική διαδικασία εξετάζει ανίχνευση η μη της δερματίτιδας (0 - αρνητική αντίδραση, 1- θετική αντίδραση) και όχι στην ανίχνευση των διαβαθμίσεων της (0 - αρνητική αντίδραση, 1 - ήπια αντίδραση, 2 - μέτρια αντίδραση και 3 - σοβαρή αντίδραση).

Κατά την προ επεξεργασία των δειγμάτων μας αρχικό βήμα αποτελεί η κατάλληλη μορφοποίηση των δεδομένων για την δημιουργία ενός ομοιόμορφου συνόλου δεδομένων. Εκτελώντας την παραπάνω διαδικασία παρατηρήθηκαν κάποιες ιδιαιτερότητες οπύ επηρεάζουν την ποιότητα κάποιων εκ των δειγμάτων μας. Πιο συγκεκριμένα κατά την διάρκεια της πρώτης εκ των δυο λήψεων υπήρξε διαρροή κόκκινου χρώματος με αποτέλεσμα η συλλογή των δειγμάτων να αλλοιωθεί. Η ενέργεια αυτή καθίσταται αναγκαία καθώς όπως θα αποδειχθεί και στην συνέχεια η ερυθρότητα του δέρματος αποτελεί βασικό χαρακτηριστικό για την ανίχνευση των μοντέλων μας. Έτσι όλα αυτά τα αλλοιωμένα αποτελέσματα θα οδηγούσαν στην απόκλιση της εκπαιδευτικής διαδικασίας και την μείωση της απόδοσης των εξεταζόμενων μοντέλων.

Εν συνεχεία στο ίδιο πλαίσιο παρατήρησης αφαιρέθηκαν από δεδομένα μας τα οι περιοχές αντίδρασης «4» και «24» καθώς όπως φαίνεται και σε προηγούμενη παράγραφο αποτελούν μαύρο και κόκκινο χρώμα αντίστοιχα. Οι συγκεκριμένες περιοχές λόγω της χρωματικής τους φύσης παρουσίαζαν υψηλούς δείκτες ερυθρότητας σε όλους τους ασθενείς υγιής και μη, με αποτέλεσμα να μην μπορούν να αποτελέσουν χρήσιμη πληροφορία για τον διαχωρισμό των παραπάνω περιπτώσεων. Στις εικόνες 15 και 16 παρατίθενται παραδείγματα που υποδηλώνουν αντίστοιχα την προβληματικότητα της κατάστασης για κάθε περιοχή.



Εικόνα 15 : Παράδειγμα περιοχής 24 όνομα ασθενή: 24726, Τετραγωνάκι: patch 24, Ετικέτα: 0



Εικόνα 16 : Παράδειγμα περιοχής 4 όνομα ασθενή: 24726, Τετραγωνάκι: patch 4, Ετικέτα: 0

7.3 Μετρικές Αξιολόγησης

Καθόλη την διάρκεια των πειραμάτων μας, για την κατανόηση και την αξιολόγηση των αποτελεσμάτων των μοντέλων που χρησιμοποιούνται για την πρόβλεψη της δερματικής πάθησης κρίθηκε αναγκαίος ο ορισμός μετρικών. Οι μετρικές αυτές βασίζονται στα true/false positive/negative δεδομένα τα οποία ορίζονται ως:

- True Positive (TP): το μοντέλο προβλέπει ορθώς ότι ο χρήστης είναι θετικός στην ασθένεια
- True Negative (TN): το μοντέλο προβλέπει ορθώς ότι ο χρήστης είναι αρνητικός στην ασθένεια
- False Positive (FP): το μοντέλο προβλέπει λανθασμένα ότι ο χρήστης είναι θετικός στην ασθένεια
- False Negative (FN): το μοντέλο προβλέπει λανθασμένα ότι ο χρήστης είναι αρνητικός στην ασθένεια

Έτσι, οι μετρικές που χρησιμοποιούνται για την αξιολόγηση των μοντέλων σε όλες τις πειραματικές διαδικασίες που εξετάστηκαν παρουσιάζονται παρακάτω :

Confusion Matrix

Το confusion matrix παρέχει εποπτική αξιολόγηση του μοντέλου καθώς αναγράφει τα true/false positive/negative.

	Κλάση 0 (predicted)	Κλάση 1 (predicted)
Κλάση 0 (actual)	True Negative	False Positive
Κλάση 1 (actual)	False Negative	True Positive

Πίνακας 5: Confusion matrix παράδειγμα

Accuracy

Το accuracy είναι μέτρο του πόσο κοντά ή μακριά είναι οι προβλέψεις από τις πραγματικές τιμές τους.

$$\text{Ορίζεται ως Accuracy} = \frac{\text{TP} + \text{TN}}{\text{TP} + \text{TN} + \text{FP} + \text{FN}}$$

Αποτελεί καλή επιλογή για τη γενική επισκόπηση των αποτελεσμάτων, ωστόσο σε περιπτώσεις ανισορροπημένων δεδομένων μπορεί να προκύψει υψηλή τιμή του accuracy που να μην αντικατοπτρίζει τη συνολική εικόνα .

Precision

Το precision είναι το ποσοστό των συνολικών προβλέψεων της κλάσης 1 που ήταν ορθές.

$$\text{Δηλαδή, ορίζεται ως } Precision = \frac{TP}{TP + FP}$$

Recall (Sensitivity)

Το recall είναι το ποσοστό των πραγματικών στιγμιότυπων της κλάσης 1 που προέβλεψε το μοντέλο.

$$\text{Δηλαδή, ορίζεται ως } Recall = \frac{TP}{TP + FN}$$

Η μετρική αυτή δίνει την πιθανότητα το μοντέλο να αναγνωρίσει ορθώς μια περίπτωση δερματίτιδας, που αποτελεί το ζητούμενο του μοντέλου. Ωστόσο, δε μπορεί να αποτελέσει τη μόνη μετρική για την ερμηνεία των αποτελεσμάτων καθώς η πρόβλεψη όλων των περιπτώσεων ως δερματίτιδα θα μας έδινε 100% recall, χωρίς να κατοπτρίζεται η αποτυχία πρόβλεψης του μοντέλου μας στην κλάση 0.

Specificity

Αντίστοιχα με το recall, το specificity είναι το ποσοστό των πραγματικών στιγμιότυπων που προβλέπει το μοντέλο αλλά για την κλάση 0 τωρα.

$$\text{Δηλαδή, ορίζεται ως } Specificity = \frac{TN}{TN + FP}$$

Η μετρική αυτή δίνει την πιθανότητα το μοντέλο να αναγνωρίσει επιτυχημένα μια αρνητική περίπτωση δερματίτιδας και παρόμοια με πριν δεν είναι αρκετή μόνη της για την συνολική αξιολόγηση ενός μοντέλου.

F1-score

Το F1-score είναι ο αρμονικός μέσος μεταξύ precision και recall.

$$\text{Έτσι, ορίζεται ως } F1\text{-score} = \frac{2 \times Recall \times Precision}{Recall + Precision} = \frac{2TP}{2TP + FP + FN}$$

Ο συνδυασμός των δύο παραπάνω μετρικών δίνει μια καλή γενική εικόνα των αποτελεσμάτων του μοντέλου.

7.4 Βασικοί αλγόριθμοι Μηχανικής Μάθησης

Με σκοπό την εύρεση της καλύτερης δυνατής ακρίβειας το σύνολο των δεδομένων δοκιμαστικέ σε 5 διαφορετικούς «παραδοσιακούς» αλγορίθμους μηχανικής μάθησης που χρησιμοποιούνται για εργασίες ταξινόμησης. Οι 5 αυτοί αλγόριθμοι άπου η θεωρία τους αναλύθηκε σε προηγούμενο κέφαλοί είναι:

- Decision Tree
- Random Forest
- Support Vector machines
- Nearest Neighbors
- Xgboost

Στα παραπάνω μοντέλα τώρα τόσο για την εκπαίδευση όσο για την αξιολόγηση των αποτελεσμάτων χρησιμοποιήθηκαν τα δεδομένα που εξήχθησαν από τις εικόνες με την χρήση του λογισμικού της pyradiomics. Τα συνολικά αριθμητικά δεδομένα προέκυψαν 54 για κάθε rgb εικόνα (18 ανά διάσταση). Διαθέτουμε 6 κανάλια εικόνων για κάθε περιοχή αντίδρασης και 42 metadata που έχουν δοθεί από το εξειδικευμένο ιατρικό προσωπικό. Επόμενος συνολικά προκύπτουν 366 δεδομένα για κάθε περιοχή αντίδρασης.

Επιπλέον, όπως αναφέρθηκε και νωρίτερα βασικό χαρακτηριστικό για την ανίχνευση της δερματίτιδας είναι η ερυθρότητα που αναπτύσσει το δέρμα στην περιοχή κατά την αντίδραση του δέρματος με την κάθε ουσία. Ωστόσο όπως είναι γνωστό υπάρχουν διάφοροι τύποι δέρματος με διάφορο φυσικό βαθμό ερυθρότητας που προκύπτει από το γενετικό υλικό και άλλων παραγόντων για τον κάθε ασθενή. Επόμενος για να αποφευχθεί λανθασμένη εκτίμηση της ερυθρότητας δίνονται για κάθε περιοχή που εισέρχεται στο μοντέλο τα δεδομένα από την αρχική (μέτρηση 1) και από την τελευταία μέτρηση (μέτρηση 1), με σκοπό να υπάρχει η πληροφορία ώστε να εξάγεται η αύξηση της ερυθρότητας σε μια περιοχή ανάμεσα στις 2 μετρήσεις και όχι ερυθρότητα αυτήν κάθε αυτήν. Επόμενος ο συνολικός αριθμός των δεδομένων αυξάνεται σε 732 δεδομένα αν περιοχή. Το παραπάνω σύνολο δεδομένων χρησιμοποιείτε για την εκπαίδευση και την αξιολόγηση των παραπάνω αλγορίθμων μηχανικής μάθησης αφού πρώτα προηγηθεί το κατάλληλο scaling και προεργασία.

7.5 Συνελικτικά δίκτυα

Τα συνελικτικά δίκτυα όπως αναφέρθηκε και στα θεωρητικά κεφάλαια αποτελούν εξαιρετικά χρήσιμο εργαλείο για τον εντοπισμό ασθενειών. Κυρίο χαρακτηριστικό τους αποτελεί η δυνατότητα να εξάγουν χαρακτηριστικά από εικόνες που ενδεχομένως δεν εντοπίζονται από το ανθρώπινο μάτι αλλά έχουν άμεση σύνδεση με τον διαχωρισμό των θετικών και αρνητικών περιπτώσεων.

Επομένως, η πειραματική διαδικασία διενεργείται τροφοδοτώντας ως είσοδο τις εικόνες που συλλέχθηκαν χωρίς να απαιτείται προεργασία για εξαγωγή δεδομένων από αυτές. Όπως συζητήθηκε στη θεωρητική ενότητα, θα χρησιμοποιήσουμε τα EfficientNet, ResNet και MobileNet για την εξαγωγή πληροφοριών από τις εικόνες. Ωστόσο, λόγω του περιορισμένου αριθμού δειγμάτων, η εκπαίδευση των δικτύων από την αρχή με μηδενικά βάρη δεν είναι εφικτή. Επομένως, χρησιμοποιούμε για προεκπαίδευση των μοντέλων το σύνολο εικόνων ImageNet και έπειτα προσαρμόζουμε τα βάρη εκπαιδύοντας τα στο δικό μας σύνολο δεδομένων. Αυτό οδηγεί στην προσαρμογή των μοντέλων ώστε να αναγνωρίζουν τα χαρακτηριστικά του δικού μας συνόλου δεδομένων. Η τεχνική αυτή ονομάζεται fine tuning και είναι ευρέως διαδομένη στον χώρο της μηχανικής μάθησης όταν πρόκειται μικρά σύνολα δοσμένων [33]. Η προσαρμογή των βαρών πραγματοποιείται με στόχο τη μεγιστοποίηση της

βαθμολογίας F1, μια μετρική που χρησιμοποιείται συνήθως σε προβλήματα ταξινόμησης, όπως η αναγνώριση ιατρών παθήσεων.

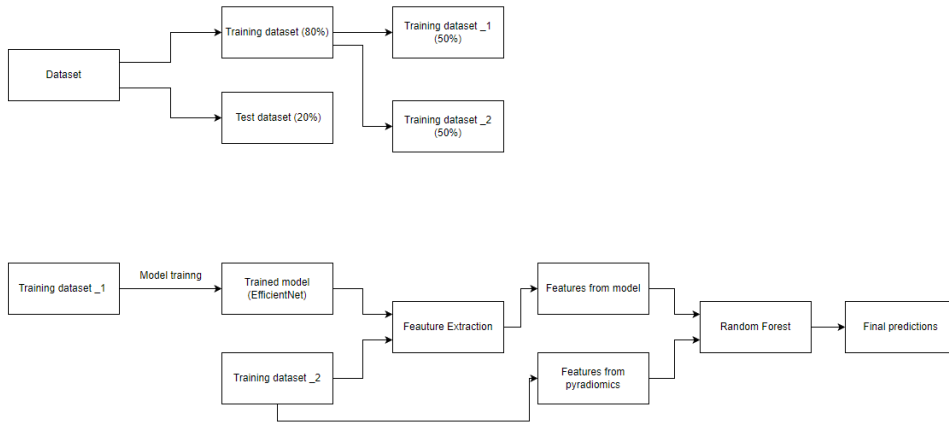
Στο πλαίσιο της ανίχνευσης δερματίτιδας, τα ψευδώς αρνητικά (περιπτώσεις δερματίτιδας που δεν προσδιορίζονται από το μοντέλο) και τα ψευδώς θετικά (περιπτώσεις που προβλέπονται ως δερματίτιδα αλλά όχι στην πραγματικότητα δερματίτιδα) έχουν σημαντικές συνέπειες. Τα ψευδώς αρνητικά μπορεί να οδηγήσουν σε καθυστερημένη θεραπεία και εξέλιξη της νόσου, ενώ τα ψευδώς θετικά μπορεί να οδηγήσουν σε περιττή θεραπεία και αυξημένο ιατρικό κόστος. Η βαθμολογία F1 συμβάλλει στον μετριασμό αυτών των συνεπειών επιτυγχάνοντας μια ισορροπία μεταξύ ακρίβειας και ανάκλησης, βελτιστοποιώντας την αντιστάθμιση μεταξύ ψευδώς αρνητικών και ψευδώς θετικών.

Οι παραδοσιακές μετρήσεις όπως η ακρίβεια, η ευαισθησία και η ειδικότητα ενδέχεται να μην παρέχουν ολοκληρωμένη αξιολόγηση για την ανίχνευση δερματίτιδας. Η ακρίβεια, η οποία μετρά την αναλογία των σωστά ταξινομημένων περιπτώσεων από όλες τις περιπτώσεις, μπορεί να μην είναι κατάλληλη όταν το σύνολο δεδομένων είναι ανισορροπημένο, με πολύ μεγαλύτερο αριθμό περιπτώσεων μη δερματίτιδας. Η ευαισθησία υπολογίζει το κλάσμα των αληθινών θετικών μεταξύ όλων των αληθινών θετικών, αλλά δεν υπολογίζει τα ψευδώς θετικά. Η ειδικότητα μετρά το κλάσμα των αληθινών αρνητικών (δηλαδή, των περιπτώσεων χωρίς δερματίτιδα) μεταξύ όλων των αληθινών αρνητικών, αλλά δεν λαμβάνει υπόψη τα ψευδώς αρνητικά. Αντίθετα, η βαθμολογία F1 προσφέρει μια πιο ολιστική αξιολόγηση της απόδοσης του μοντέλου στην ανίχνευση δερματίτιδας.

7.6 Συνδυασμός μεθόδων

Υπό το πρίσμα του πλαισίου ανάπτυξης εφαρμογών και της συνεχιζόμενης έρευνας στο κεφάλαιο 6 για τη συγχώνευση μεθόδων, διενεργείται έρευνα για την απόδοση ενός συνδυασμένου μοντέλου που ενσωματώνει τις προαναφερθείσες περιπτώσεις. Η εφαρμογή αυτής της μεθοδολογίας περιλαμβάνει τη διαίρεση των δεδομένων σε δύο διακριτές υποομάδες. Το πρώτο υποσύνολο χρησιμοποιείται για την εκπαίδευση του βέλτιστου μοντέλου EfficientNet, όπως προσδιορίστηκε μέσω προηγούμενου πειραματισμού. Στη συνέχεια, το εκπαιδευμένο μοντέλο χρησιμοποιείται για την εξαγωγή χαρακτηριστικών από τα δεδομένα της δεύτερης υποομάδας.

Αυτά τα εξαγόμενα χαρακτηριστικά στη συνέχεια συνδυάζονται με τα υπάρχοντα χαρακτηριστικά που προέρχονται από την πυραδιωμική, χρησιμεύοντας ως είσοδο στον ανώτερο «παραδοσιακό» αλγόριθμο μηχανικής εκμάθησης Random Forest. Για την εξασφάλιση ακριβών αποτελεσμάτων, η μέθοδος διασταυρούμενης επικύρωσης χρησιμοποιείται σε όλη την προαναφερθείσα διαδικασία. Η συνολική διαδικασία συνδυασμού μεθόδων αναπαρίσταται οπτικά και περιγράφεται αναλυτικά στο Σχήμα 17, παρέχοντας βελτιωμένη οπτικοποίηση και καλύτερη κατανόηση της μεθοδολογίας που υιοθετήθηκε.



Εικόνα 17 : Διάγραμμα ροής συνδυαστικής μεθόδου

Κεφάλαιο 8. Αποτελέσματα

8.1 Βασικοί αλγόριθμοι Μηχανικής Μάθησης

Η διερεύνηση των ερευνητικών υποθέσεων και συλλογισμών που αναπτύχθηκαν παραπάνω διεξάγεται μέσω τριών διαδοχικών πειραματικών διαδικασιών. Ο στόχος είναι να προσδιοριστεί η βέλτιστη διαμόρφωση για την ανίχνευση δερματίτιδας διερευνώντας διάφορες εναλλακτικές λύσεις μέσω της προσαρμογής διαφορετικών παραμέτρων και αλγορίθμων μηχανικής εκμάθησης. Το πειραματικό πλαίσιο περιλαμβάνει ένα κοινό σύνολο δεδομένων και ενσωματώνει τεχνικές βελτιστοποίησης που στοχεύουν στην επίτευξη της υψηλότερης δυνατής ακρίβειας.


Αρχικά, δεδομένης της μη ισορροπημένης φύσης του συνόλου δεδομένων που αποκαλύφθηκε κατά την ανάλυση δεδομένων, η εφαρμογή τεχνικών υπερδειγματοληψίας ή υποδειγματοληψίας καθίσταται απαραίτητη. Επιπλέον, η διερεύνηση της σημασίας των χαρακτηριστικών και ο αντίκτυπός τους στην πρόβλεψη του μοντέλου παρέχει πολύτιμες πληροφορίες για τους παράγοντες που σχετίζονται άμεσα με την αναγνώριση της νόσου. Αυτές οι πληροφορίες είναι εξαιρετικά πολύτιμες, καθώς επιτρέπουν εστιασμένες και βελτιστοποιημένες μετρήσεις γύρω από τους πιο σημαντικούς προγνωστικούς παράγοντες, οδηγώντας έτσι σε βελτιωμένα αποτελέσματα. Επιπλέον, διερευνώνται τα πιθανά πλεονεκτήματα της χρήσης ενός υποσυνόλου χαρακτηριστικών για την αξιολόγηση των δυνατοτήτων για βελτιωμένα αποτελέσματα. Κατά τη διάρκεια αυτών των πειραμάτων, η απόδοση των επιλεγμένων μοντέλων αξιολογείται σχολαστικά, ενσωματώνοντας τις γνώσεις που αποκτήθηκαν από αυτές τις αξιολογήσεις για τη διαμόρφωση της μεθοδολογίας που θα υιοθετηθεί. Είναι σημαντικό να τονιστεί ότι τα αποτελέσματα που παρουσιάζονται παρακάτω αφορούν ταξινομητές που έχουν υποβληθεί σε εξαντλητική αναζήτηση για τον προσδιορισμό των βέλτιστων τιμών για συγκεκριμένες υπερπαραμέτρους.

8.2 Βασικοί αλγόριθμοι Μηχανικής Μάθησης


Το πρώτο πείραμα που διεξήχθη περιλαμβάνει την αξιολόγηση διαφόρων ταξινομητών για τον εντοπισμό των καταλληλότερων για την πρόβλεψη των περιπτώσεων των ασθενών. Οι ταξινομητές που εξετάστηκαν σε αυτό το πείραμα περιλαμβάνουν το Random Forest, το Decision Tree, το Support Vector Machine (SVM), το K-Nearest Neighbors (KNN) και το XGBoost. Το πείραμα ακολουθεί τα συμπεράσματα που προέκυψαν από προηγούμενα πειράματα, χρησιμοποιώντας Τυχαία υπερδειγματοληψία, καθώς αποδείχθηκε ως πιο αποτελεσματική. Επιπλέον τα αποτελέσματα που φαίνονται στις εικόνες 18 και 19 προέκυψαν χρησιμοποιώντας τον ίδιο διαχωρισμό του συνόλου δεδομένων σε υποσύνολα, με σκοπό τα αποτελέσματα να είναι συγκρίσιμα και να μην βασίζονται στην τυχαιότητα των υποσυνόλων.

Στην Εικόνα 18 εμφανίζεται το Confusion Matrix του ταξινομητή Random Forest, τα δεδομένα του οποίου έπειτα από τις εξισώσεις που αναφέρονται στο προηγούμενο κεφάλαιο παράγουν τις τιμές της ακρίβειας (Accuracy), της συνέπειας (Precision), της ανάκλησης (recall), της βαθμολογίας F1 (F1-score) και ειδικότητας (specificity) που παρουσιάζονται στην

Εικόνα 19. Το γράφημα αποκαλύπτει ότι οι ταξινομητές SVM και KNN παρουσιάζουν χειρότερη απόδοση σε σύγκριση με τους άλλους ταξινομητές, ιδιαίτερα όσον αφορά την βαθμολογία F1 και την συνέπεια. Από την άλλη πλευρά, οι ταξινομητές που βασίζονται σε δέντρα αποφάσεων αποδίδουν εξαιρετικά καλά για αυτό το συγκεκριμένο πρόβλημα. Μεταξύ αυτών, ο ταξινομητής Random Forest ξεχωρίζει ως η κορυφαία απόδοση, αν και αυτό μπορεί να αποδοθεί στον συγκεκριμένο διαχωρισμό δοκιμής αμαξοστοιχίας που χρησιμοποιήθηκε στο πείραμα. Λαμβάνοντας υπόψη ότι οι υπόλοιποι ταξινομητές που βασίζονται σε δέντρα επιδεικνύουν επίσης ευνοϊκή απόδοση, θα χρησιμοποιήσουμε έναν συνδυασμό μοντέλων για την ανάπτυξη της προτεινόμενης μεθοδολογίας, όπως συζητήθηκε στο προηγούμενο κεφάλαιο.




Εικόνα 18: Προβλέψεις Random Forest και Xgboost




Εικόνα 19: Αποτελέσματα παραδοσιακών αλγορίθμων μηχανικής μάθησης

Δεδομένου ότι το συνολικό μέγεθος για κάθε δείγμα 732 χαρακτηρίστηκα η διαδικασία εκπαίδευσης των μοντέλων είναι κοστοβόρα τόσο σε χρόνο όσο και σε υπολογιστική δύναμη. Έτσι σε συνέχεια της προηγούμενης πειραματικής διαδικασίας εξετάζουμε το feature importance των χαρακτηριστικών μας, με σκοπό να εντοπίσουμε τα χαρακτηριστικά που επηρεάζουν περισσότερο την τελική απόφαση των μοντέλων. Στο πλαίσιο αυτής της διαδικασίας εξετάζονται τα μοντέλα Random Forest και Xgboost, στα οποία αναλύεται η σημασία όλων των χαρακτηριστικών τους, όπως φαίνεται στα διαγράμματα 20 και 21.



Εικόνα 20 Random Forest σημαντικότητα χαρακτηριστικών



Εικόνα 21 : Xgboost σημαντικότητα χαρακτηριστικών

Όπως φαίνεται και στα παραπάνω γραφήματα η πλειοψηφία των χαρακτηριστικών δεν έχουν σημαντική επιρροή στις αποφάσεις του μοντέλου καθώς δεν παρέχουν αρκετά σημαντική πληροφορία για τον διαχωρισμό των δυο κλάσεων (Αντίδραση δερματιδα-1 ή όχι

Αντίδραση δερματιδας-0). Έτσι μπορούμε να ερευνήσουμε την μείωση της διάστασης του πίνακα των χαρακτηριστικών κρατώντας τα 20 πιο σημαντικά χαρακτηριστικά (βασιζόμενοι σε κάποιο κατώφλι importance) τα οποία παρατίθενται με αύξουσα σειρά παρακάτω.

Πιο συγκριμένα στους πίνακες 6 και 7 παρατίθενται σε φθίνουσα σειρά τα αντίστοιχα 20 πιο σημαντικά χαρακτηριστικά τόσο για το Random Forest όσο και για το Xgboost.

<i>Pos.</i>	<i>Image</i>	<i>Feature Name</i>	<i>Imp.</i>
1	546	Redness72h features_g original_firstorder_10Percentile	0.18
2	705	metadat72h Redness - Variation	0.07
3	563	Redness72h features_g 'original_firstorder_Variance'	0.05
4	553	Redness72h features_g 'original_firstorder_MeanAbsoluteDeviation'	0.03
5	701	metadat72h Redness - Score	0.02
6	651	Volumes72h features_r 'original_firstorder_TotalEnergy'	0.02
7	638	Volumes72h features_r 'original_firstorder_Energy'	0.01
8	561	Redness72h features_g 'original_firstorder_TotalEnergy'	0.01
9	548	Redness72h features_g 'original_firstorder_Energy'	0.01
10	528	Redness72h features_r 'original_firstorder_10Percentile'	0.01
11	704	metadat72h Redness - Maximum	0.01
12	558	Redness72h features_g 'original_firstorder_RobustMeanAbsoluteDeviation'	0.01
13	550	Redness72h features_g 'original_firstorder_InterquartileRange'	0.01
14	317	Volumes0h features_b 'original_firstorder_Range'	0.01
15	555	Redness72h features_g 'original_firstorder_Median'	0.01
16	693	metadat72h Color - a* average	0.01
17	245	Texture0h features_g 'original_firstorder_Range'	0.01
18	269	Texture0h features_b 'original_firstorder_Variance'	0.01
19	492	Folds72h features_g 'original_firstorder_10Percentile'	0.01
20	491	Folds72h features_r 'original_firstorder_Variance'	0.004

Πίνακας 6: Random Forest σημαντικότητα χαρακτηριστικών


Xgboost:

<i>Pos.</i>	<i>Image</i>	<i>Feature Name</i>	<i>Imp.</i>
1	546	Redness72h features_g original_firstorder_10Percentile	0.3
2	492	Folds72h features_r 'original_firstorder_Variance'	0.1
3	467	FineLines72h features_b 'original_firstorder_Range'	0.07
4	553	Redness72h features_g 'original_firstorder_MeanAbsoluteDeviation'	0.04
5	317	Volumes0h features_b 'original_firstorder_Range'	0.04
6	427	FineLines72h features_r 'original_firstorder_Maximum'	0.04
7	529	Redness72h features_r 'original_firstorder_90Percentile'	0.03
8	364	Metadata0h Volumes - Conforming area (mm ²)	0.03

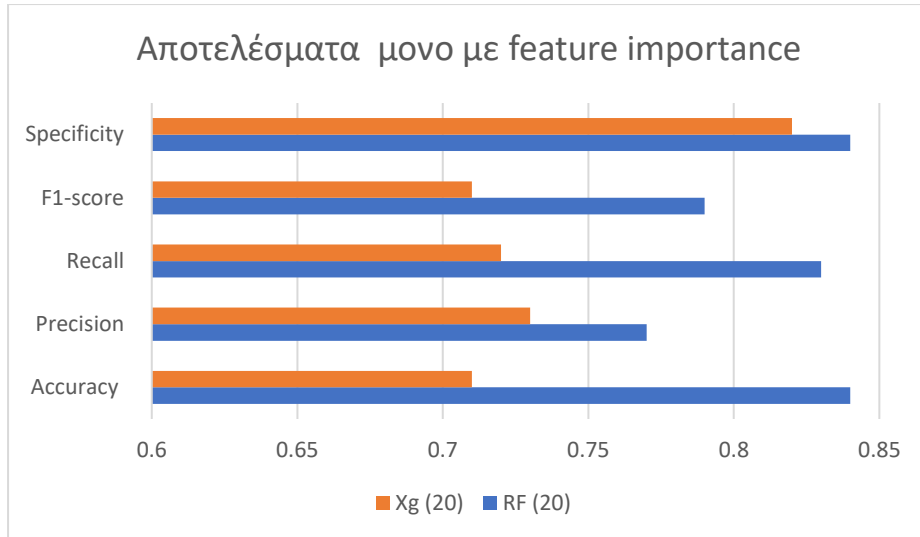
9	701	Metadata72h	Redness - Score	0.02
10	164	Redness0h	features_r 'original_firstorder_Energy'	0.02
11	335	Metadata0h	Redness - Minimum	0.02
12	530	Redness72h	features_r 'original_firstorder_Energy'	0.01
13	38	Colour0h	features_b 'original_firstorder_Energy'	0.01
14	72	FineLines0h	features_g 'original_firstorder_10Percentile'	0.01
15	563	Redness72h	features_g 'original_firstorder_Variance'	0.01
16	281	Volumes0h	features_r 'original_firstorder_Range'	0.01
17	197	Redness0h	features_g 'original_firstorder_Variance'	0.01
18	582	Texture72h	features_r 'original_firstorder_10Percentile'	0.01
19	182	Redness0h	features_g 'original_firstorder_90Percentile'	0.01
20	371	Colour72h	features_r 'original_firstorder_Kurtosis'	0.01

Πίνακας 7: Xgboost σημαντικότητα χαρακτηριστικών

Στον επόμενο πείραμα, χρησιμοποιώντας τα νέα μειωμένων διαστάσεων χαρακτηριστικά, εκπαιδεύουμε τα μοντέλα μας τα οποία επιτυγχάνουν πολύ καλά αποτελέσματα όπως φαίνεται και στην Εικόνα 23. Στην εικόνα 22 παρουσιάζονται οι συνολικές προβλέψεις για τα δυο μοντέλα που συμμετείχαν και παρατηρείτε ότι υπάρχει βελτίωση και για τους δυο αλγορίθμους σε σχέση με τις προηγούμενες διατάξεις. Η συγκεκριμένη συμπεριφορά οφείλετε ενδεχομένως στην αφαίρεση θορύβου που επιτευχθεί με την αφαίρεση των υπολοίπων χαρακτηριστικών. Το γεγονός αυτό είναι αναμενόμενο σύνολα δεδομένων μεγάλη διάσταση στα χαρακτηριστικά τους.




Εικόνα 22: Αποτελέσματα μόνο με feature importance



Εικόνα 23: Αποτελέσματα μονο με feature importance

Τέλος, στο γράφημα της εικόνας 24 παρουσιάζονται όλες οι πειραματικές διατάξεις και οι αποδώσεις τους, με αυτήν του Random Forest με την μειωμένη διάσταση χαρακτηριστικών να επιτυγχάνει την καλύτερη από αυτές.




Εικόνα 24: Γράφημα Συνολικων αποτελεσματων βασικων αλθοροισμων μηχανικης μαθησας


8.2 Συνελκτικικά δίκτια

Όπως αναφέρθηκε και στο κεφάλαιο της μεθοδολογίας εκπαιδεύουμε και αξιολογούμε τρία διαφορετικά προ εκπαιδευμένα (στο ImageNet) μοντέλα EfficientNet, ResNet και MobileNet για όλα τα 6 κανάλια εικόνων που διαθέτουμε (Color, Fine Line, Folds, Redness, Texture and Volumes). Στα 3 διαδοχικά πειράματα που παρουσιάζονται παρακάτω, για τα τρία συνελκτικικά δίκτια, έχουν διατηρηθεί ίδιες σταθερές εκπαίδευσης. Πιο συγκεκριμένα όπως αναφέρθηκε και σε προηγούμενο κεφάλαιο χρησιμοποιούμε Adam optimizer, μέθοδο απώλειας categorical_crossentropy και μετρική βελτίωσης την βαθμολογία F1 (F1-score). Επιπλέον όλα τα μοντέλα εκπαιδεύτηκαν για 60 επαναλήψεις στο σύνολο δεδομένων που συλλέχτηκαν από την πειραματική διαδικασία.


Στην εικόνα 25 παρουσιάζονται οι confusion matrixes του μοντέλου EfficientNet για κάθε κανάλι εικόνων. Παρατηρείται ότι τα κανάλια Fine Line και Volumes δεν αποδίδουν καθόλου καλά καθώς χάνουν πάνω από το 50% θετικών περιπτώσεων, με την καλύτερη απόδοση να σημειώνετε από το κανάλι της Ερυθρότητας (Redness).

Η παραπάνω παρατήρηση επιβεβαιώνεται και από το συγκεντρωτικό γράφημα της εικόνας 26 όπου είναι εμφανές το Redness περιέχει την περισσότερη πληροφορία και σημειώνει τα καλύτερα αποτελέσματα σε όλες τις μετρικές που αξιολογούμε.





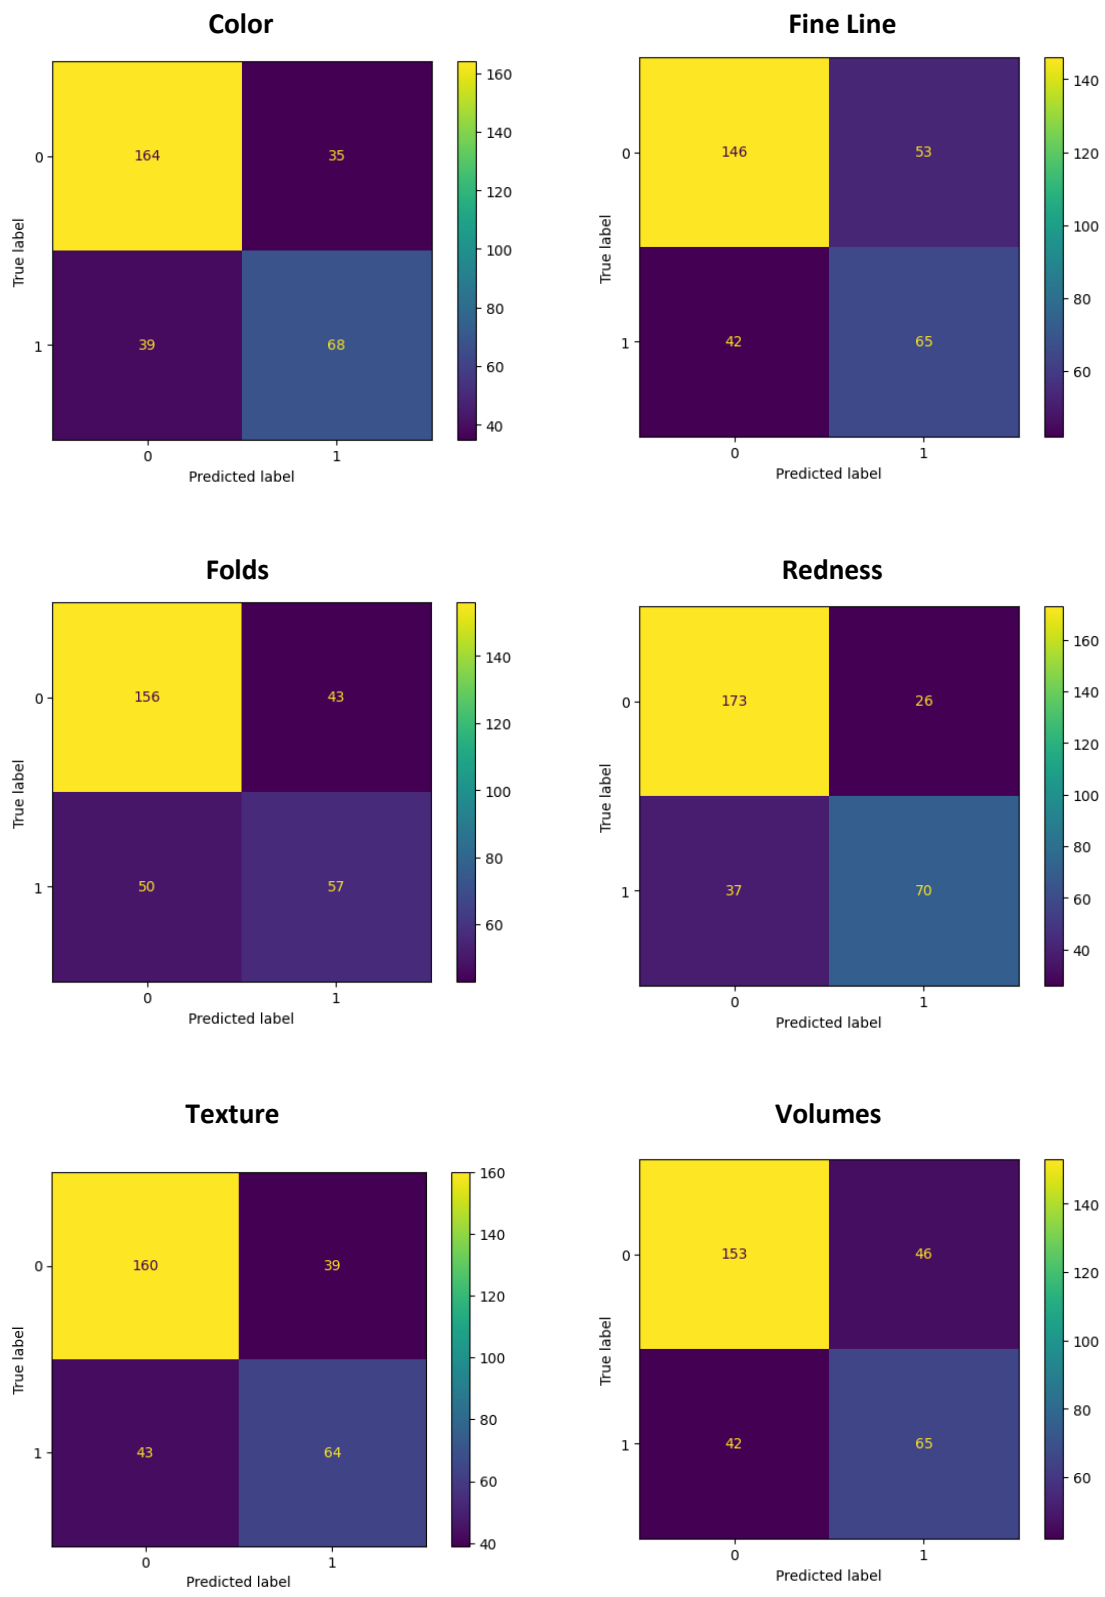
Εικόνα 25: Αποτελέσματα μοντέλου EfficientNet




Εικόνα 26: Αποτελέσματα μοντέλου EfficientNet

Στην περίπτωση του Resnet τώρα εξάγονται τα ίδια διαγράμματα με την προηγούμενη πειραματική διαδικασία. Παρατηρείτε ότι και σε αυτήν περίπτωση από τις εικόνες 27 και 28

το Resnet έχει την ίδια συμπεριφορά με το Efficinetnet ωστόσο οι απόδοση του είναι πιο χαμηλή σε σχέση με αυτό. Παρόλα αυτά και πάλι το κανάλι της ερυθρότητας επιτυγχάνει την καλύτερες τιμές στο διάγραμμα 28 σε σχέση με τα υπόλοιπα.




Εικόνα 27: Αποτελέσματα μοντέλου ResNet




Εικόνα 28: Αποτελέσματα μοντέλου ResNet

Στην περίπτωση του Mobilenet, δημιουργήθηκαν τα ίδια διαγράμματα με αυτά της προηγούμενης πειραματικής διαδικασίας. Ωστόσο, είναι προφανές ότι η απόδοση του Mobilenet δεν είναι ίδια με τους δύο προηγούμενους αλγόριθμους. Όπως φαίνεται στις εικόνες 29 και 30, το Mobilenet δεν έχει ικανοποιητική απόδοση ακόμη και στο κανάλι ερυθρότητα. Επιπλέον, σε σύγκριση με τους άλλους αλγόριθμους, το Mobilenet εμφανίζει μεγαλύτερο αριθμό λανθασμένων αρνητικών περιπτώσεων, ιδιαίτερα στα κανάλια Color και Volumes. Κατά συνέπεια, η συγκεκριμένη διαμόρφωση δεν κρίνεται βέλτιστη για τη συγκεκριμένη μελέτη.



Εικόνα 29: Αποτελέσματα μοντέλου MobileNet




Εικόνα 30: Αποτελέσματα μοντέλου MobileNet


8.3 Συνδυασμός μεθόδων

Το παρακάτω πείραμα στοχεύει να διερευνήσει τον συνδυασμό αλγορίθμων μηχανικής μάθησης, ειδικά του Random Forest και ενός CNN (EfficientNet), προκειμένου να βελτιώσει την απόδοση του συστήματος στον εντοπισμό της ασθένειας. Με βάση τα ευρήματα προηγούμενων πειραμάτων, τα οποία αφορούσαν ταξινομητές Random Forest και EfficientNet, διερευνούμε τώρα την απόδοση του συνδυασμού αυτών των αλγορίθμων. Αυτό το πείραμα ακολουθεί την ίδια μεθοδολογία όπως πριν, χρησιμοποιώντας Τυχαία υποδειγματοληψία σε ολόκληρο το σύνολο δεδομένων χωρίς χρονικούς περιορισμούς. Τα αποτελέσματα παρουσιάζονται στο σχήμα 32.

Το Σχήμα 31 περιλαμβάνει το confusion matrix του προαναφερθέντος συνδυαστικού μοντέλου, και παρουσιάζει την απόδοση του στο ίδιο test σύνολο δεδομένων που χρησιμοποιήθηκε στα προηγούμενα στάδια. Όπως γίνεται αντιληπτό ο συνδυασμός των παραπάνω αλγορίθμων οδηγεί σε μικρή βελτίωση κατά την τελική πρόβλεψη. Πιο συγκεκριμένα στο διάγραμμα 32 παρατηρείται διατήρηση της επίδοσης σε όλες σχεδόν τις μετρικές με μικρή βελτίωση να συναντάται στις περιπτώσεις της βαθμολογίας F1 και της ειδικότητας.




Εικόνα 31: Αποτελέσματα συνδυαστικής μεθόδου



Εικόνα 32: Αποτελέσματα συνδυαστικής μεθόδου

Δεδομένης της αυξημένης διάστασης των χαρακτηριστικών, η σημασία των χαρακτηριστικών προσλαμβάνει ακόμη μεγαλύτερη σημασία σε αυτό το πείραμα. Όπως απεικονίζεται στο γράφημα 33, η πλειονότητα των χαρακτηριστικών εμφανίζει ελάχιστη επιρροή στη διαδικασία λήψης αποφάσεων του μοντέλου. Τα αποτελέσματα με τα πιο σημαντικά από αυτά να είναι και φθίνουσα σειρά παρατίθενται στον Πίνακα 8.




Εικόνα 33: Διάγραμμα feature Importance στην συνδυαστική μέθοδο

<i>Pos.</i>	<i>Image</i>	<i>Feature Name</i>
1	546 Redness72h	features_g original_firstorder_10Percentile
2	705 metadat72h	Redness - Variation
3	558 Redness72h	features_g 'original_firstorder_RobustMeanAbsoluteDeviation'
4	370 Colour72h	features_r 'original_firstorder_InterquartileRange'
5	693 metadat72h	Color - a* average
6	563 Redness72h	features_g 'original_firstorder_Variance'
7	553 Redness72h	features_g 'original_firstorder_MeanAbsoluteDeviation'
8	550 Redness72h	features_g 'original_firstorder_InterquartileRange'
9	1957	Feature from CNN
10	1014	Feature from CNN
11	863	Feature from CNN
12	555 Redness72h	features_g 'original_firstorder_Median'
13	573 Redness72h	features_b 'original_firstorder_Median'
14	1293	Feature from CNN
15	491 Folds72h	features_r 'original_firstorder_Variance'
16	396 Colour72h	features_g 'original_firstorder_Median'
17	1314	Feature from CNN
18	391 Colour72h	features_g 'original_firstorder_MeanAbsoluteDeviation'
19	803	Feature from CNN
20	922	Feature from CNN
21	1539	Feature from CNN
22	1143	Feature from CNN
23	704 metadat72h	Redness - Maximum
23	532 Redness72h	features_r 'original_firstorder_InterquartileRange'


24	1818		Feature from CNN
25	701	metadat72h	Redness - Score
26	1697		Feature from CNN
27	1860		Feature from CNN
28	1838		Feature from CNN
29	317	Volumes0h	features_b 'original_firstorder_Kurtosis'
30	1343		Feature from CNN
31	274	Volumes0h	features_r 'original_firstorder_InterquartileRange'
32	311	Volumes0h	features_b 'original_firstorder_Range'
33	604	Texture72h	features_r 'original_firstorder_Entropy'
34	1302		Feature from CNN
35	1520		Feature from CNN
36	548	Redness72h	features_g 'original_firstorder_Energy'
37	569	Redness72h	features_b 'original_firstorder_Maximum'
38	1926		Feature from CNN
39	816		Feature from CNN
40	1180		Feature from CNN

Πίνακας 8: Σημαντικά χαρακτηριστικά για τον συνδυασμό μεθόδων

Στο τελικό πείραμα, μετά τη μείωση της διαστάσεων των χαρακτηριστικών από το 2012 στο 40, προκύπτουν τα ακόλουθα αποτελέσματα. Το Σχήμα 34, το οποίο παρουσιάζει τις τελικές προβλέψεις, δείχνει μια σχετική διατήρηση της ακρίβειας παρά τη σημαντική μείωση των δεδομένων πληροφορίας. Αυτή η παρατήρηση υποστηρίζεται περαιτέρω από το Σχήμα 35, που απεικονίζει τις συγκρίσιμες μετρικές απόδοσης μεταξύ των δύο πειραμάτων. Οπότε επιτυγχάνουμε παρόμοια αποτελέσματα χρησιμοποιώντας πολύ λιγότερη υπολογιστική ισχύ.



Εικόνα 34: Τελικά αποτελέσματα συνδυαστικής μεθόδου



Εικόνα 35:Τελικά αποτελέσματα συνδυαστικής μεθόδου

Συνολικά, τα αποτελέσματα της συνδυασμένης προσέγγισης δείχνουν μια οριακή βελτίωση σε σύγκριση με τις προηγούμενες επιμέρους τεχνικές πρόβλεψης. Αυτή η παρατηρούμενη συμπεριφορά ευθυγραμμίζεται με τα ευρήματα που αναφέρθηκαν από τον Keerthana D στο "Υβριδικά συνελκτικά νευρωνικά δίκτυα με ταξινομητή SVM για ταξινόμηση του καρκίνου του δέρματος", όπως συζητήθηκε σε προηγούμενο κεφάλαιο, όπως αναμενόταν [30].

8.4 Ανάλυση αποτελεσμάτων

Αρχικά, εστιάζοντας στην ανάλυση της σημαντικότητας χαρακτηριστικών που εκτελέστηκε στα πλαίσια τους αρχικού πειράματος, βλέπε πίνακες 6,7,8, συμπεραίνουμε ότι τα χαρακτηριστικά που εμφανίζονται στον Πίνακα 9 εμπεριέχουν πολύτιμη πληροφορία για των διαχωρισμό των περατώσεων καθώς συναντιούνται σχεδόν πάντα στις πρώτες θέσεις σημαντικότητας σε όλες τις αναλύσεις. Κοινός παρονομαστής των παρακάτω χαρακτηριστικών είναι ότι εκφράζουν μετρικές και δείκτες που σχετίζονται με την ερυθρότητα (Redness). Επιπλέον όπως παρατηρήθηκε και στα πειράματα που εξετάστηκαν τα συνελκτικά δίκτυα, βλέπε γραφήματα 26,28 και 30, το Redness έχει την καλύτερη επίδοση σε σύγκριση με τα υπόλοιπα κανάλια.

Pos.	Image	Feature Name
1	546	Redness72h features_g original_firstorder_10Percentile
2	705	metadat72h Redness - Variation
3	563	Redness72h features_g 'original_firstorder_Variance'
4	553	Redness72h features_g 'original_firstorder_MeanAbsoluteDeviation'
5	701	metadat72h Redness - Score

Πίνακας 9: Σημαντικά χαρακτηριστικά σε όλες τις πειραματικές διαδικασίες

Δεδομένου των παραπάνω δυο αναλύσεων μπορούμε με ασφάλεια να θεωρήσουμε ότι η ερυθρότητα αποτελεί σημαντικό χαρακτηριστικό για την ανίχνευση δερματίτιδας. Η έντονη αυτή συσχέτιση μπορεί να αποτελέσει σημαντικό παράγοντα στην τροποποίηση και την εξέλιξη των διαγνωστικών μεθόδων γύρω από την σύνδεση της ερυθρότητας και των δερματικών παθήσεων. Το έγχρωμο κανάλι εμφανίζεται ως δευτερεύον στοιχείο σημαντικότητας, καθώς τα υπόλοιπα κανάλια συμβάλλουν ελάχιστα στην ακριβή ταξινόμηση και διαφοροποίηση των περιπτώσεων..

Επιπλέον, και στις τρεις πειραματικές προσεγγίσεις, τα επιτευχθέντα επίπεδα απόδοσης συγκλίνουν σε εύρος ακρίβειας 83-85%. Στο πλαίσιο της έρευνας που διεξήχθη σε περιπτώσεις εσφαλμένης ταξινόμησης, έχουν εντοπιστεί δύο πιθανοί εξωτερικοί παράγοντες που θα μπορούσαν να επηρεάσουν την απόδοση των μοντέλων. Ο πρωταρχικός και κύριος περιορισμός, όπως συζητήθηκε σε προηγούμενα κεφάλαια, σχετίζεται με την ανεπαρκή ποσότητα δεδομένων. Ακόμη και η παραμικρή αστοχία, που δεν μπορεί να αποδοθεί στην εκπαίδευση του μοντέλου, μπορεί να ασκήσει σημαντική επίδραση στην απόδοση λόγω της σημαντικής αναλογίας της στο συνολικό σύνολο δεδομένων δοκιμής.


Ένας ακόμα περιορισμός που προέκυψε από την ανάλυση του συνόλου δεδομένων, που οφείλεται στην φύση αυτήν κάθε αυτήν της πειραματικής διαδικασίας, είναι η ύπαρξη γειτονικότητας στις εξεταζόμενες περιοχές. Το επίθεμα, όπως παρουσιάζεται στην εικόνα 4 του κεφαλαίου **Error! Reference source not found.**, με το οποίο συλλέγονται οι εικόνες που χρησιμοποιούνται στις πειραματικές διαδικασίες, διαθέτει περιοχές, οι οποίες βρίσκονται η μια δίπλα στην άλλη.

Το φαινόμενο αυτό δεν λαμβάνεται υπόψιν κατά τις διαδικασίες εκπαίδευσης και την ταξινόμησης των εξεταζόμενων μοντέλων. Κατά συνέπεια, προκύπτουν καταστάσεις όπου η αντίδραση εκτείνεται πέρα από τον καθορισμένο θάλαμο, ιδιαίτερα σε περιπτώσεις έντονων αντιδράσεων που ταξινομούνται ως βαθμού 2 και 3. Αυτή η επέκταση οδηγεί σε αυξημένες τιμές ερυθρότητας στις γειτονικές περιοχές. Κατά συνέπεια, δημιουργούνται δείγματα που παρουσιάζουν αυξημένη ερυθρότητα, τα οποία, βάσει ιατρικών αξιολογήσεων, δεν υποδεικνύουν θετική αντίδραση δερματίτιδας. Αυτές οι περιπτώσεις περιλαμβάνονται τόσο στη φάση εκπαίδευσης όσο και στη φάση αξιολόγησης του μοντέλου και λόγω του περιορισμένου όγκου δεδομένων, αποτελούν σημαντικό μέρος που μπορεί να επηρεάσει την απόδοση των πειραματικών διαδικασιών.


Σε ένα παράδειγμα των παραπάνω περιπτώσεων αναλύουμε τα δεδομένα του ασθενή 24625. Στον πίνακα 10 παρατίθενται οι ετικέτες όλων των περιοχών ενδιαφέροντος για τον συγκεκριμένο ασθενή. Στην συνέχεια στην εικόνα 36 πατηθείτε οι εικόνες που συλλέχθηκαν για το patch 1. Παρατηρώντας τις παρακάτω εικόνες γίνεται αντιληπτό ότι οι περιοχές 2,3 και 7 από patch 1- area 1 και η εικόνα 4 από patch 1- area 2 παρουσιάζουν τιμές αυξημένης ερυθρότητας σε σύγκριση πάντα με την μέτρηση στις 0 ώρες. Ωστόσο όπως φαίνεται στον πίνακα 10 οι περιπτώσεις 2,4 και 7 αξιολογούνται ως αρνητικές στην αντίδραση με δερματίτιδα. Επιπλέον παρατηρούμε και από την εικόνα 4 του κεφαλαίου **Error! Reference source not found.** αλλά και την εικόνα 36 ότι οι περιοχές 2 και 4 είναι γειτονικές με την περιοχή 3 στην οποία συναντάται οξεία αντίδραση βαθμού 3 (Πίνακας 10). Έτσι η εξάπλωση της αντίδρασης οδηγεί στην αύξηση της ερυθρότητας των παραπάνω περιοχών ενώ δεν συναντάται αντίδραση σε αυτές. Όπως είδαμε και νωρίτερα από τον Πίνακα 9 η ερυθρότητα αποτελεί πολύ σημαντική παράμετρο για την αναγνώριση της δερματίτιδας. Έτσι γίνεται αντιληπτό ότι τέτοιες «λανθασμένα» ταξινομημένες περιπτώσεις επηρεάζουν τόσο την εκπαίδευση όσο και την διαδικασία ταξινόμησης των μοντέλων μας.

Patch	Substance	Label (48h)	Label (72h)
2 patch 1- area 1	Neomycin Sulphate	0	0
3 patch 1- area 1	Thiuram Mix	2	3
4 patch 1- area 2	Paraphenylenediamine	0	0
7 patch 1- area 1	Formaldehyde	0	0
8 patch 1- area 1	Colophonium	0	2
24 patch 3- area 2	Textile Dye Mix	0	0


Πίνακας 10: Ετικέτες δειγμάτων ασθενή 24625




patch 1- area 1 - Redness (0 hours)



patch 1- area 1 - Redness (72 hours)



patch 1- area 2 - Redness (0 hours)




patch 1- area 2 - Redness (72 hours)

Εικόνα 36: Παράδειγμα επιρροής γειτονικότητας

Μια ενδεχομένη ενέργεια, που θα μπορούσε να επιλύσει και να μετριάσει τον παραπάνω περιορισμό, αποτελεί η ανάπτυξη ενός αλγόριθμου που λαμβάνει υπόψιν την σύνδεση των γειτονικών περιοχών. Για παράδειγμα στις περιπτώσεις έντονης δερματίτιδας, οι γειτονική περιοχή να προσαρμόζονται με ανάλογο τρόπο, ώστε τα βάρη και τις τιμές της ερυθρότητας

της εικόνας ώστε να λαμβάνεται υπόψιν τόσο στην ταξινόμηση όσο και στην εκπαίδευση του μοντέλου.

Τέλος, ένας ακόμα λόγος που ενδεχομένως να οδηγεί τα μοντέλα σε λανθασμένες προβλέψεις και στην μείωση της ακρίβειας είναι η υποκειμενικότητα της παρατήρησης. Όπως αναφέρθηκε και στο κεφάλαιο 2 οι ετικέτες παράχθηκαν κατά την κρίση του εξειδικευμένου ιατρικού προσωπικού. Ωστόσο λόγο της ύπαρξης διάφορων παρατηρητών αλλά και της υποκειμενικότητας τους, υπάρχουν περιπτώσεις με παρομοίους δείκτες ερυθρότητας που άλλοτε κατηγοριοποιούνται ως θετική αντίδραση δερματίτιδας και άλλοτε όχι. Για παράδειγμα στην Εικόνα 37 παρατίθεται μια περίπτωση υποκειμενικής αξιολόγησης με αρνητική τιμή ενός δείγματος με αρκετά υψηλούς δείκτες ερυθρότητας. Η παρακάτω περίπτωση έρχεται σε αντίθεση με τα συμπεράσματα των παραπάνω διαδικασιών και ενδεχομένως ταξινομείται λανθασμένα κατά τις πειραματικές διαδικασίες επηρεάζοντας την συνολική απόδοση.



Όνομα ασθενή: 24726, Chamber : patch 27, Ετικέτα: 0

Εικόνα 37: Παράδειγμα υποκειμενικότητας κριτή

Κεφάλαιο 9. Συμπεράσματα

9.1 Εισαγωγή

Σκοπός της παρούσας διπλωματικής εργασίας ήταν να διερευνήσει την εφαρμογή αλγορίθμων μηχανικής μάθησης και μοντέλων συνελκτικών νευρωνικών δικτύου (CNN) για την ακριβή διάγνωση αλλεργικών αντιδράσεων δερματίτιδας από φωτογραφίες με δοκιμές patch. Η έρευνα περιελάμβανε τρία πειράματα, το καθένα διερεύνησε διαφορετικές προσεγγίσεις και τεχνικές.

Αναλύοντας περαιτέρω τα αποτελέσματα, στο πρώτο πείραμα, χρησιμοποιήθηκαν παραδοσιακοί αλγόριθμοι μηχανικής μάθησης όπως το Random Forest, το Xgboost, το Decision Tree, το SVM και το KNN. Μετά τη διεξαγωγή ανάλυσης σπουδαιότητας χαρακτηριστικών και την μείωση της διάστασης των συνολικών χαρακτηριστικών, βρέθηκε ότι το Random Forest πέτυχε την υψηλότερη ακρίβεια 84%. Η παραπάνω επίδοση ήταν αρκετά υψηλότερη από τις υπόλοιπες μεθόδους, βλέπε διάγραμμα 24, καταδεικνύοντας έτσι την αποτελεσματικότητα του Random Forest στην ακριβή διάγνωση αλλεργικών αντιδράσεων.

Στην συνέχεια, προχωρώντας στο δεύτερο πείραμα που εξετάστηκαν μοντέλα CNN συμπεριλαμβανομένων των EfficientNet, ResNet και MobileNet. Αυτά τα μοντέλα εκπαιδεύτηκαν και δοκιμάστηκαν στο ίδιο σύνολο δεδομένων με το προηγούμενο πείραμα ώστε να είναι η εφικτή η σύγκριση των αποτελεσμάτων. Μεταξύ αυτών, το EfficientNet αναδείχθηκε ως το μοντέλο με τις κορυφαίες επιδόσεις, επιτυγχάνοντας ακρίβεια 84%. Αυτό υπογραμμίζει ότι και τα CNN έχουν αξιόπιστες επιδόσεις στην ταξινόμηση των αλλεργικών αντιδράσεων από φωτογραφίες επιθεμάτων.

Με βάση τα ευρήματα των επιμέρους πειραμάτων, το τρίτο και τελευταίο πείραμα είχε ως στόχο να συνδυάσει τους αλγόριθμους με την καλύτερη απόδοση. Μετά τη διενέργεια ανάλυσης σημασίας χαρακτηριστικών και την εκ νέου μείωση της διάστασης των συνδυασμένων των χαρακτηριστικών, παρατηρήθηκε περαιτέρω βελτίωση στην μικρή ακρίβεια, φτάνοντας το 85%. Αυτό το αποτέλεσμα τονίζει τα οφέλη από τη μόχλευση ενός συνδυασμού αλγορίθμων μηχανικής μάθησης για τη βελτίωση της διαγνωστικής ακρίβειας των αλλεργικών αντιδράσεων.

Τα αποτελέσματα αυτής της έρευνας συμβάλλουν στον τομέα της δερματολογίας παρουσιάζοντας τις δυνατότητες των τεχνικών μηχανικής μάθησης στην αυτοματοποίηση της ταξινόμησης των αλλεργικών αντιδράσεων. Μειώνοντας την επιβάρυνση των ασθενών και των συστημάτων υγειονομικής περίθαλψης, η αυτοματοποιημένη ταξινόμηση από φωτογραφίες μπορεί να βελτιώσει την πρόσβαση στην περίθαλψη και να εξορθολογίσει τη διαγνωστική διαδικασία.

9.2 Ανάλυση των μελλοντικών βημάτων

Συμπερασματικά, τα ευρήματα αυτής της διατριβής υπογραμμίζουν την αποτελεσματικότητα των Random Forest, EfficientNet και του συνδυασμού τους στην ακριβή

διάγνωση αλλεργικών αντιδράσεων με βάση τις φωτογραφίες patch. Αυτά τα αποτελέσματα καταδεικνύουν τις τεράστιες δυνατότητες των αλγορίθμων μηχανικής μάθησης στον τομέα της δερματολογίας και θέτουν τα θεμέλια για μελλοντικές εξελίξεις στην αυτοματοποιημένη διάγνωση.

Παρά το περιορισμένο σύνολο δεδομένων και τις προαναφερθείσες προκλήσεις που συζητήθηκαν στην προηγούμενη υποενότητα, επιτεύχθηκε ένα εντυπωσιακό ποσοστό επιτυχίας 85%. Αυτή η απόδοση αποδόθηκε στη χρήση προεκπαιδευμένων μοντέλων. Ωστόσο, σε περίπτωση μεγαλύτερου μεγέθους δείγματος, θα μπορούσαν να εξεταστούν τα μοντέλα εκπαίδευσης από την αρχή για τη διερεύνηση εναλλακτικών προσεγγίσεων. Μια ουσιαστική μελλοντική κατεύθυνση που αναμένεται να αποφέρει βελτιωμένα αποτελέσματα περιλαμβάνει τη βελτίωση του αλγόριθμου ανίχνευσης γειτονικών περιοχών, όπως αναλύθηκε στην προηγούμενη παράγραφο. Αυτή η βελτίωση στοχεύει να εξηγήσει τη χωρική εγγύτητα των περιοχών και τη διάδοση του κοκκινίσματος από τη μια περιοχή στην άλλη.

Περαιτέρω ερευνητικές προσπάθειες θα μπορούσαν να επικεντρωθούν στην απόκτηση πρόσθετων δεδομένων από ασθενείς που ακολουθούν μια παρόμοια διαδικασία για να αυξηθεί το σύνολο δεδομένων εκπαίδευσης. Επιπλέον, η εξερεύνηση εναλλακτικών αλγορίθμων και τεχνικών μηχανικής μάθησης στο προαναφερθέν σύνολο δεδομένων ενδεχομένως οδηγήσει στην επίτευξη ανώτερων αποτελεσμάτων, καθώς πολλοί συνδυασμοί παραμένουν ανεξερεύνητοι.

Θα πρέπει να σημειωθεί ότι η αξιολόγηση των αποτελεσμάτων μας στερείται συγκριτικών στοιχείων από παρόμοια πειράματα, γεγονός που περιορίζει την έκταση των συμπερασμάτων μας. Ανάμεσα στις λίγες σχετικές μελέτες, ο W.H. Η εργασία των Chan και R. Srivastava [15] σχετικά με την ανίχνευση δερματίτιδας χρησιμοποιώντας μηχανική μάθηση παρουσιάζει κάποιο βαθμό ομοιότητας, επιτυγχάνοντας μια βαθμολογία F1 0,89, αποτέλεσμα συγκρίσιμο με τα δικά μας ερευνητικά ευρήματα.

Επιπλέον, μια φυσική εξέλιξη συνεπάγεται την ανάπτυξη συνολικού λογισμικού που, σε συνδυασμό με το κατάλληλο υλικό, που να μπορεί να εκτελέσει αυτόνομα τη διάγνωση της νόσου. Ένα τέτοιο λογισμικό θα μπορούσε να χρησιμεύσει ως συμβουλευτικό διαγνωστικό εργαλείο για γιατρούς σε κεντρικές τοποθεσίες και ως αυτόνομο σύστημα σε απομακρυσμένες περιοχές χωρίς εξειδικευμένο προσωπικό. Διευκολύνοντας τον εντοπισμό και την έγκαιρη θεραπεία πολλών περιπτώσεων δερματίτιδας, η χρήση ενός τέτοιου εργαλείου θα συμβάλει σημαντικά στην αντιμετώπιση του υψηλού επιπολασμού αυτής της νόσου. Επιπλέον, η συνεχής συλλογή δεδομένων μέσω της εφαρμογής της θα προωθήσει περαιτέρω την κατανόηση της συγκεκριμένης πάθησης και την αντιμετώπισή της.

Συνολικά, αυτή η έρευνα προσφέρει πολύτιμες γνώσεις σχετικά με την εφαρμογή της μηχανικής μάθησης στη δερματολογία και ανοίγει δρόμους για μελλοντική εξερεύνηση σε αυτόν τον τομέα.

Βιβλιογραφία

- [1] “Atopic Dermatitis (Eczema) - Dermatologic Disorders - MSD Manual Professional Edition.” <https://www.msmanuals.com/professional/dermatologic-disorders/dermatitis/atopic-dermatitis-eczema#top> (accessed May 22, 2023).
- [2] R. BERKE, A. SINGH, and M. GURALNICK, “Atopic Dermatitis: An Overview,” *Am Fam Physician*, vol. 86, no. 1, pp. 35–42, Jul. 2012, Accessed: May 22, 2023. [Online]. Available: <https://www.aafp.org/pubs/afp/issues/2012/0701/p35.html>
- [3] I. Kimber, D. A. Basketter, G. F. Gerberick, and R. J. Dearman, “Allergic contact dermatitis,” *Int Immunopharmacol*, vol. 2, no. 2–3, pp. 201–211, Feb. 2002, doi: 10.1016/S1567-5769(01)00173-4.
- [4] A. K. Gupta and R. Bluhm, “Seborrheic dermatitis,” *Journal of the European Academy of Dermatology and Venereology*, vol. 18, no. 1, pp. 13–26, Jan. 2004, doi: 10.1111/J.1468-3083.2004.00693.X.
- [5] A. K. C. Leung, J. M. Lam, K. F. Leong, A. A. M. Leung, A. H. C. Wong, and K. L. Hon, “Nummular Eczema: An Updated Review,” *Recent Pat Inflamm Allergy Drug Discov*, vol. 14, no. 2, pp. 146–155, Jan. 2021, doi: 10.2174/1872213X14666200810152246.
- [6] P. M. Calle Sarmiento and J. J. Chango Azanza, “Dyshidrotic Eczema: A Common Cause of Palmar Dermatitis,” *Cureus*, vol. 12, no. 10, Oct. 2020, doi: 10.7759/CUREUS.10839.
- [7] T. Searle, F. R. Ali, and F. Al-Niaimi, “Perioral dermatitis: Diagnosis, proposed etiologies, and management,” *J Cosmet Dermatol*, vol. 20, no. 12, pp. 3839–3848, Dec. 2021, doi: 10.1111/JOCD.14060.
- [8] S. Sundaresan, M. R. Migden, and S. Silapunt, “Stasis Dermatitis: Pathophysiology, Evaluation, and Management,” *Am J Clin Dermatol*, vol. 18, no. 3, pp. 383–390, Jun. 2017, doi: 10.1007/S40257-016-0250-0.
- [9] M. D. P. Davis, S. A. Hylwa, and E. M. Allen, “Basics of patch testing for allergic contact dermatitis,” *Semin Cutan Med Surg*, vol. 32, no. 3, pp. 158–168, Sep. 2013, doi: 10.12788/J.SDER.0029.
- [10] J. Marks *et al.*, “North American Contact Dermatitis Group patch test results for the detection of delayed-type hypersensitivity to topical allergens,” *J Am Acad Dermatol*, vol. 38, no. 6, pp. 911–918, Jun. 1998, doi: 10.1016/S0190-9622(98)70587-0.
- [11] J. H. Lee, S. W. Son, and S. H. Cho, “A Comprehensive Review of the Treatment of Atopic Eczema,” *Allergy Asthma Immunol Res*, vol. 8, no. 3, p. 181, 2016, doi: 10.4168/AAIR.2016.8.3.181.
- [12] Y. Xue *et al.*, “Global Burden, Incidence and Disability-Adjusted Life-Years for Dermatitis: A Systematic Analysis Combined With Socioeconomic Development Status, 1990–2019,” *Front Cell Infect Microbiol*, vol. 12, Apr. 2022, doi: 10.3389/fcimb.2022.861053.

- [13] E. Kowalska-Olędzka, M. Czarnecka, and A. Baran, "Epidemiology of atopic dermatitis in Europe," *J Drug Assess*, vol. 8, no. 1, pp. 126–128, 2019, doi: 10.1080/21556660.2019.1619570.
- [14] Y. Xue *et al.*, "Global Burden, Incidence and Disability-Adjusted Life-Years for Dermatitis: A Systematic Analysis Combined With Socioeconomic Development Status, 1990–2019," *Front Cell Infect Microbiol*, vol. 12, pp. 327–91, Apr. 2022, doi: 10.3389/FCIMB.2022.861053/FULL.
- [15] W. H. Chan *et al.*, "Automated detection of skin reactions in epicutaneous patch testing using machine learning," *Br J Dermatol*, vol. 185, no. 2, pp. 456–458, Aug. 2021, doi: 10.1111/BJD.20141.
- [16] A. Esteva *et al.*, "Dermatologist-level classification of skin cancer with deep neural networks," *Nature*, vol. 542, no. 7639, pp. 115–118, Feb. 2017, doi: 10.1038/NATURE21056.
- [17] P. Tschandl *et al.*, "Comparison of the accuracy of human readers versus machine-learning algorithms for pigmented skin lesion classification: an open, web-based, international, diagnostic study," *Lancet Oncol*, vol. 20, no. 7, pp. 938–947, Jul. 2019, doi: 10.1016/S1470-2045(19)30333-X.
- [18] "Antera 3D® User Manual."
- [19] Z. R. Wang, Y. L. Jia, H. Hua, and S. M. Tang, "Pedestrian detection using boosted HOG features," *IEEE Conference on Intelligent Transportation Systems, Proceedings, ITSC*, pp. 1155–1160, 2008, doi: 10.1109/ITSC.2008.4732553.
- [20] Y. Ke and R. Sukthankar, "PCA-SIFT: A more distinctive representation for local image descriptors," *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, vol. 2, 2004, doi: 10.1109/CVPR.2004.1315206.
- [21] M. Jogin, Mohana, M. S. Madhulika, G. D. Divya, R. K. Meghana, and S. Apoorva, "Feature extraction using convolution neural networks (CNN) and deep learning," *2018 3rd IEEE International Conference on Recent Trends in Electronics, Information and Communication Technology, RTEICT 2018 - Proceedings*, pp. 2319–2323, May 2018, doi: 10.1109/RTEICT42901.2018.9012507.
- [22] M. Tkalčič and J. F. Tasič, "Colour spaces - Perceptual, historical and applicational background," *IEEE Region 8 EUROCON 2003: Computer as a Tool - Proceedings*, vol. A, pp. 304–308, 2003, doi: 10.1109/EURCON.2003.1248032.
- [23] D. G. Green, "The contrast sensitivity of the colour mechanisms of the human eye," *J Physiol*, vol. 196, no. 2, pp. 415–429, May 1968, doi: 10.1113/JPHYSIOL.1968.SP008515.
- [24] R. Mohammed, J. Rawashdeh, and M. Abdullah, "Machine Learning with Oversampling and Undersampling Techniques: Overview Study and Experimental Results," *2020 11th International Conference on Information and Communication Systems, ICICS 2020*, pp. 243–248, Apr. 2020, doi: 10.1109/ICICS49469.2020.239556.
- [25] X. Huang, G. Jin, and W. Ruan, "Machine Learning Basics," pp. 3–13, 2023, doi: 10.1007/978-981-19-6814-3_1.

- [26] Z.-H. Zhou, "Machine Learning," 2021, doi: 10.1007/978-981-15-1967-3.
- [27] T. Chen and C. Guestrin, "XGBoost: A scalable tree boosting system," *Proceedings of the ACM SIGKDD International Conference on Knowledge Discovery and Data Mining*, vol. 13-17-August-2016, pp. 785–794, Aug. 2016, doi: 10.1145/2939672.2939785.
- [28] A. Zarandy, C. Rekeczky, P. Szolgay, and L. O. Chua, "Overview of CNN research: 25 years history and the current trends," *Proceedings - IEEE International Symposium on Circuits and Systems*, vol. 2015-July, pp. 401–404, Jul. 2015, doi: 10.1109/ISCAS.2015.7168655.
- [29] M. Tan and Q. V. Le, "EfficientNet: Rethinking Model Scaling for Convolutional Neural Networks," *36th International Conference on Machine Learning, ICML 2019*, vol. 2019-June, pp. 10691–10700, May 2019, Accessed: Jun. 01, 2023. [Online]. Available: <https://arxiv.org/abs/1905.11946v5>
- [30] D. Keerthana, V. Venugopal, M. K. Nath, and M. Mishra, "Hybrid convolutional neural networks with SVM classifier for classification of skin cancer," *Biomedical Engineering Advances*, vol. 5, p. 100069, Jun. 2023, doi: 10.1016/J.BEA.2022.100069.
- [31] E. U. H. Qazi, M. H. Faheem, and T. Zia, "HDLNIDS: Hybrid Deep-Learning-Based Network Intrusion Detection System," *Applied Sciences 2023, Vol. 13, Page 4921*, vol. 13, no. 8, p. 4921, Apr. 2023, doi: 10.3390/APP13084921.
- [32] H. Wang *et al.*, "Mitosis detection in breast cancer pathology images by combining handcrafted and convolutional neural network features," <https://doi.org/10.1117/1.JMI.1.3.034003>, vol. 1, no. 3, p. 034003, Oct. 2014, doi: 10.1117/1.JMI.1.3.034003.
- [33] N. Tajbakhsh *et al.*, "Convolutional Neural Networks for Medical Image Analysis: Full Training or Fine Tuning?," *IEEE Trans Med Imaging*, vol. 35, no. 5, pp. 1299–1312, May 2016, doi: 10.1109/TMI.2016.2535302.