

ΣΧΟΛΗ ΜΗΧΑΝΙΚΩΝ
ΤΜΗΜΑ ΜΗΧΑΝΙΚΩΝ ΠΛΗΡΟΦΟΡΙΚΗΣ
ΚΑΙ ΗΛΕΚΤΡΟΝΙΚΩΝ ΣΥΣΤΗΜΑΤΩΝ

ΔΙΠΛΩΜΑΤΙΚΗ ΕΡΓΑΣΙΑ

Διάγνωση Μελανώματος με χρήση Κινητής Συσκευής



Του φοιτητή
Χατζιωαννίδης Δανιήλ
Αρ. Μητρώου: 2021233

Επιβλέπων
Ονοματεπώνυμο Τζέκης
Παναγιώτης
Βαθμίδα Καθηγητής

Ημερομηνία 09/09/2025

Τίτλος Δ.Ε. **Διάγνωση Μελανώματος με χρήση Κινητής Συσκευής**

Κωδικός Δ.Ε. **25251**

Όνοματεπώνυμο φοιτητή **Χατζιωαννίδης Δανιήλ**

Όνοματεπώνυμο εισηγητή **Τζέκης Παναγιώτης**

Ημερομηνία ανάληψης Δ.Ε. **04-04-2025**

Ημερομηνία περάτωσης Δ.Ε. **19-11-2025**

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

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

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

Στους γονείς μου

Πρόλογος

Η διπλωματική εργασία αποτελεί την τελική εκτίμηση των σπουδών μου και αντιπροσωπεύει την πρώτη μου απόπειρα στην εφαρμοσμένη μηχανική μάθηση για την υγειονομική περίθαλψη. Το έργο που παρουσιάζω αφορά την ανάπτυξη και την εφαρμογή ενός μοντέλου βαθιάς μάθησης για την εκτίμηση της πιθανότητας δερματικών βλαβών, το οποίο είναι ενσωματωμένο σε μια εφαρμογή για κινητά τηλέφωνα που αποσκοπεί στην υποστήριξη, και όχι στην αντικατάσταση, της επαγγελματικής ιατρικής κρίσης.

Η ιδέα ξεκίνησε όταν διαπίστωσα ότι πολλοί άνθρωποι διαθέτουν κινητές συσκευές, αλλά έχουν περιορισμένη πρόσβαση σε δερματολόγο και συχνά καθυστερούν να ζητήσουν συμβουλή για βλάβες που τους προκαλούν ανησυχία. Ήθελα να δω αν τα σύγχρονα μοντέλα υπολογιστικής οπτικής, σε συνδυασμό με έξυπνο σχεδιασμό και σαφή μηνύματα ασφαλείας, θα μπορούσαν να καλύψουν, τουλάχιστον, ένα μικρό μέρος αυτού του κενού.

Ελπίζω ότι η εργασία θα αποτελέσει την αρχή για περισσότερες διεπιστημονικές προσπάθειες με σκοπό την υπεύθυνη συνένωση της επιστήμης των υπολογιστών, της ιατρικής και του σχεδιασμού, με στόχο την ευαισθητοποίηση και τη βοήθεια στην ανίχνευση του καρκίνου του δέρματος.

Επέλεξα το θέμα «**Διάγνωση Μελανώματος με χρήση Κινητής Συσκευής**» επειδή η πρόωπη ανίχνευση μπορεί να αλλάξει τα τελικά αποτελέσματα ενός ανθρώπου και ήθελα ένα προϊόν που να είναι κατανοητό και πάνω από όλα χρήσιμο. Ο στόχος απλός: να παρέχει γρήγορη ανάλυση με την χρήση ενός τυπικού τηλεφώνου.

Αυτό το έργο μου έμαθε μηχανική μάθηση και γνώση ως προς την δημιουργία κινητών εφαρμογών, αλλά και υπευθυνότητα: τεκμηρίωση ορίων, εξέταση αυτού που αποκαλώ ψευδώς αρνητικά αποτελέσματα και προστασία των δεδομένων των χρηστών.

Περίληψη

Η διπλωματική αυτή εργασία εξετάζει την ανάπτυξη, την εκπαίδευση και την εφαρμογή ενός μοντέλου deep learning για την αξιολόγηση του κινδύνου δερματικών βλαβών, καθώς και την ενσωμάτωση αυτού του μοντέλου σε μια εφαρμογή για smartphone που προορίζεται ως εργαλείο ενημέρωσης, αλλά δεν αντικαθιστά ούτε απαιτεί την ιατρική κρίση ενός επαγγελματία υγείας. Με αφορμή την αυξανόμενη συχνότητα εμφάνισης μελανώματος και την πανταχού παρούσα πρόσβαση σε smartphone, η εργασία αυτή διερευνά το ερώτημα εάν ένας αποτελεσματικός κατηγοριοποιητής βασισμένος σε εικόνες μπορεί να παρέχει κλινικά σημαντικές εκτιμήσεις κινδύνου σε μια χρωστική δερματική βλάβη σε πραγματικές, μη κλινικές συνθήκες. Το προτεινόμενο σύστημα βασίζεται σε ένα ConvNeXt-Tiny backbone μαζί με ένα Squeeze-and-Excitation (SE) block και έχει εκπαιδευτεί ως δυαδικός ταξινομητής σε μια περικομμένη έκδοση του δερματοσκοπικού συνόλου δεδομένων HAM10000. Για μεγαλύτερη ανθεκτικότητα σε κοινά προβλήματα που παρατηρούνται στις εικόνες των καταναλωτών, πραγματοποιείται εκτεταμένη προεπεξεργασία και αύξηση των δεδομένων. Η ανισορροπία των κλάσεων αντιμετωπίζεται μέσω της υπερδειγματοληψίας των κακοήθων περιπτώσεων, καθώς και με την εφαρμογή σταθμισμένης απώλειας στις κλάσεις κατά τη διάρκεια της εκπαίδευσης.

Όταν ολοκληρωθεί, το μοντέλο εξάγεται στο TensorFlow Lite και επικυρώνεται τόσο με την έκδοση Keras όσο και με την έκδοση TFLite, προκειμένου να επιβεβαιωθεί η παρόμοια συμπεριφορά του μοντέλου σε όλα τα περιβάλλοντα. Διεξάγεται μια δομημένη αναζήτηση κατωφλίου για να διερευνηθεί ποσοτικά η σχέση ευαισθησίας και ειδικότητας και να προσδιοριστούν σημεία λειτουργίας με υψηλή ευαισθησία σε κακοήθεις βλάβες. Αυτά τα σημεία λειτουργίας χρησιμοποιούνται στη συνέχεια για τον καθορισμό ζωνών χαμηλού, μεσαίου και υψηλού κινδύνου εντός ρητής προδιαγραφής σχετικά με το ποσοστό κακοηθειών στην περιοχή χαμηλού κινδύνου, σύμφωνα με μια προσέγγιση σχεδιασμού που δίνει προτεραιότητα στην ασφάλεια. Το μοντέλο TFLite που προκύπτει ενσωματώνεται σε μια εφαρμογή Flutter για κινητά που εμπλέκει τον χρήστη στη διαδικασία λήψης εικόνων, εκτελεί έναν βασικό έλεγχο ποιότητας εικόνας, περιγράφει και κοινοποιεί πληροφορίες κινδύνου χρησιμοποιώντας απλή γλώσσα και άμεσες δηλώσεις αποποίησης ευθύνης. Συνοπτικά, η εργασία δείχνει ότι μια ολοκληρωμένη διαδικασία από το σύνολο δεδομένων, στο μοντέλο της συσκευής, έως τη διεπαφή εμπλοκής των χρηστών που γνωρίζουν τους κινδύνους είναι τεχνικά εφικτή και μπορεί να χρησιμεύσει ως βάση για μελλοντική διεπιστημονική εργασία που περιλαμβάνει κλινική επικύρωση και μελέτες χρηστών.

Melanoma Diagnosis Using a Mobile Device

Chatziioannidis Daniil

Abstract

This thesis examines the development, training, and implementation of a deep learning model for assessing the risk of skin lesions, as well as the integration of this model into a smartphone application intended as an information tool, but which does not replace or require the medical judgment of a healthcare professional. Given the increasing incidence of melanoma and the ubiquitous access to smartphones, this work investigates whether an effective image-based classifier can provide clinically meaningful risk assessments for a pigmented skin lesion in real, non-clinical settings. The proposed system is based on a ConvNeXt-Tiny backbone together with a Squeeze-and-Excitation (SE) block and has been trained as a binary classifier on a cropped version of the HAM10000 dermatoscopic dataset. For greater robustness to common problems observed in consumer images, extensive preprocessing and data augmentation are performed. Class imbalance is addressed through oversampling of malignant cases, as well as by applying class weighted loss during training.

Once complete, the model is exported to TensorFlow Lite and validated with both the Keras and TFLite versions to confirm similar model behavior across all environments. A structured threshold search is performed to quantitatively explore the relationship between sensitivity and specificity and identify operating points with high sensitivity to malignant lesions. These operating points are then used to define low-, medium-, and high-risk zones within an explicit specification regarding the percentage of malignancies in the low-risk zone, in accordance with a safety-first design approach. The resulting TFLite model is integrated into a Flutter mobile application that engages the user in the image capture process, performs a basic image quality check, describes and communicates risk information using plain language and straightforward disclaimers. In summary, the work shows that an integrated process from the dataset, to the device model, to the risk-aware user engagement interface is technically feasible and can serve as a basis for future interdisciplinary work involving clinical validation and user studies.

Ευχαριστίες

Θέλω να ευχαριστήσω την οικογένεια μου, η οποία με στήριξε απόλυτα σε όλη την διάρκεια της φοίτησής μου. Επίσης θέλω να ευχαριστήσω τον Καθηγητή κ. Τζέκη Παναγιώτη που μου έδωσε την ευκαιρία να ασχοληθώ με αυτό το ενδιαφέρον θέμα.

Περιεχόμενα

Πρόλογος.....	iii
Περίληψη.....	iv
Abstract	v
Ευχαριστίες	vi
Περιεχόμενα	vii
Κατάλογος Σχημάτων	x
Συντομογραφίες.....	xi
Κεφάλαιο 1ο: Εισαγωγή.....	1
1.1 Εισαγωγή.....	1
1.2 Περιγραφή του προβλήματος και πεδίο εφαρμογής.....	2
1.3 Στόχοι και συνεισφορές.....	3
1.4 Δομή.....	4
Κεφάλαιο 2ο: Ανασκόπηση	6
2.1 Καρκίνος του δέρματος και έγκαιρη ανίχνευση.....	6
2.2 Δερματοσκοπική απεικόνιση και σύνολα δεδομένων	7
2.3 Μηχανική μάθηση και βαθιά μάθηση για την ταξινόμηση εικόνων	8
2.4 Αυτοματοποιημένη ανάλυση δερματικών βλαβών.	8
2.5 Εφαρμογές κινητής υγείας και συμπεράσματα στη συσκευή	9
2.6 Ηθικά και κανονιστικά ζητήματα.....	10
2.7 Σύγχρονα μοντέλα βαθιάς μάθησης στη δερματολογία	11
2.8 Συγκριτική ανασκόπηση των συστημάτων αξιολόγησης δερματικών βλαβών	12
Κεφάλαιο 3ο: Σύνολο δεδομένων και προεπεξεργασία	14
3.1 Σύνολο δεδομένων	14
3.2 Εκχώρηση ετικετών και διαχωρισμός συνόλων εκπαίδευσης και επικύρωσης	16
3.3 Προεπεξεργασία εικόνων	17
3.4 Αύξηση δεδομένων και Ανισορροπία κλάσεων	17
3.5 Στρατηγικές εμπλουτισμού και γενίκευσης των συνόλων δεδομένων.....	18
3.6 Κλινικά μεταδεδομένα, ποιότητα ετικετών και μεροληψίες σε σύνολα δεδομένων	20
3.7 Λεπτομέρειες υλοποίησης του αγωγού δεδομένων	21
3.8 Συμπεράσματα.....	23
Κεφάλαιο 4ο: Αρχιτεκτονική μοντέλου και διαδικασία εκπαίδευσης	25
4.1 Γενική προσέγγιση	25

4.2	Βασική γραμμή ConvNeXt-Tiny και προδιαγραφές εισόδου	26
4.3	Προσοχή στο κανάλι με συμπίεση και διέγερση	28
4.4	Κεφαλή ταξινόμησης.....	29
4.5	Συνάρτηση απώλειας, μετρήσεις και βελτιστοποίηση	30
4.6	Σχέδιο εκπαίδευσης και πρόωρος τερματισμός.....	31
4.7	Εξερεύνηση πρακτικών ζητημάτων ανάπτυξης εκπαίδευσης προσανατολισμένης στην ανάπτυξη	32
4.8	Αρχιτεκτονικοί περιορισμοί και πιθανές μελλοντικές εργασίες.....	34
4.9	Σύνοψη	35
Κεφάλαιο 5ο: Αξιολόγηση και επιλογή κατωφλίου.....		36
5.1	Ρύθμιση αξιολόγησης.....	36
5.2	Απόδοση επικύρωσης του μοντέλου Keras.....	37
5.3	Συνεκτικότητα μεταξύ μοντέλων Keras και μοντέλων TensorFlow Lite.....	38
5.4	Αναζήτηση κατωφλίου στις εξόδους του TensorFlow Lite	39
5.5	Ορισμός ζωνών χαμηλού, μεσαίου και υψηλού κινδύνου	40
5.6	Ανάλυση σφαλμάτων	41
5.7	Ανακεφαλαίωση.....	42
Κεφάλαιο 6ο: Εξαγωγή μοντέλου και ενσωμάτωση σε κινητά.....		44
6.1	Μετατροπή σε TensorFlow Lite.....	44
6.2	Αρχιτεκτονική εφαρμογής και ενσωμάτωση μοντέλου	46
6.3	Αξιολόγηση της ποιότητας της εικόνας στη συσκευή.....	49
6.4	Αντιστοίχιση πιθανοτήτων με μηνύματα κινδύνου.....	50
6.5	Σύνοψη	52
Κεφάλαιο 7ο: Συζήτηση και ηθικές απόψεις		53
7.1	Ερμηνεία της απόδοσης και των επιλογών κατωφλίου	53
7.2	Ανθεκτικότητα και γενικευσιμότητα.....	55
7.3	Ηθικές σκέψεις, περιορισμοί και συμπεράσματα.....	56
Κεφάλαιο 8ο: Παραδείγματα και επεξήγηση χρήσης εφαρμογής.....		59
8.1	Επεξήγηση.....	59
.....		59
8.2	Παράδειγμα υψηλής επικινδυνότητας.....	61
8.3	Παράδειγμα χαμηλής επικινδυνότητας	62
Κεφάλαιο 9ο: Συμπέρασμα και μελλοντικές εργασίες.....		63
9.1	Συμπέρασμα	63
9.2	Μελλοντικές έρευνες.....	65

Κατάλογος Σχημάτων

Σχήμα 1.1: Διάγραμμα ροής εφαρμογής	2
Σχήμα 2.1: Ενδεικτικά παραδείγματα καλοήθων και κακοήθων δερματικών βλαβών από το σύνολο δεδομένων HAM10000.....	7
Σχήμα 2.2: Σύγκριση δερματοσκοπικής εικόνας με τυπική φωτογραφία καταναλωτή.....	8
Σχήμα 3.1: Κατανομή των διαγνωστικών κατηγοριών στο σύνολο δεδομένων HAM10000, η οποία τονίζει την ανισορροπία μεταξύ καλών και κακών αλλοιώσεων.....	15
Σχήμα 3.2: Διαφοροποίηση εικόνων μεταξύ Benign και Malignant.....	16
Σχήμα 3.3: Παράδειγμα από εικόνες που έχουν περάσει από την διαδικασία του augmentation.....	17
Σχήμα 4.1: Αρχιτεκτονική convnext-tiny.....	26
Σχήμα 4.2: Μπλοκ Squeeze and Excitation που υπολογίζει βάρη προσοχής ανά κανάλι και ανασταθμίζει του χάρτη χαρακτηριστικών.....	28
Σχήμα 5.1: Καμπύλη ROC στο σύνολο επικύρωσης HAM10000.....	38
Σχήμα 5.2: Σχηματική απεικόνιση ζωνών.....	41
Σχήμα 6.1: Διάγραμμα ροής αλληλεπίδρασης χρήστη εφαρμογής.....	46
Σχήμα 6.2: Ενδεικτικά Screenshot εφαρμογής.....	49
Σχήμα 6.3: Αναλυτικό διάγραμμα ροής αξιολόγησης εικόνας.....	50

Συντομογραφίες

Δ.Ε.	Διπλωματική Εργασία
ΔΙΠΑΕ	Διεθνές Πανεπιστήμιο Ελλάδος
Π.Ε.	Πτυχιακή Εργασία
ML	Machine Learning
TFLite	TensorFlow Lite

Κεφάλαιο 1ο: Εισαγωγή

1.1 Εισαγωγή

Το μελάνωμα είναι μια από τις πιο επιθετικές μορφές καρκίνου του δέρματος. Αντιπροσωπεί ένα μικρότερο ποσοστό του καρκίνου του δέρματος σε σύγκριση με τις καλοήθεις δερματικές βλάβες, αλλά ευθύνεται για το μεγαλύτερο ποσοστό θανάτων που σχετίζονται με τον καρκίνο του δέρματος, όταν αυτό δεν εντοπιστεί ή δεν έχει αξιολογηθεί σε πρώιμο στάδιο [5]. Η παρούσα εργασία δεν αποσκοπεί στην παροχή ιατρικής διάγνωσης αλλά στην διερεύνηση μεθόδων εκτίμησης του κινδύνου κακοήθειας δερματικών βλαβών. Η πρόγνωση που σχετίζεται με το μελάνωμα βελτιώνεται σημαντικά με την αναγνώριση και την έγκαιρη αναγνώριση και παρέμβαση. Για τον λόγο αυτό, η έγκαιρη αξιολόγηση των υπόπτων δερματικών βλαβών αποτελεί ζήτημα δημοσίας υγείας.

Πράγματι, πολλά άτομα παρατηρούν την εμφάνιση ή την αλλαγή μιας νέας ελιάς στο δέρμα τους, αλλά καθυστερούν να επισκεφθούν έναν δερματολόγο. Οι λόγοι για αυτό ποικίλλουν, από την υποτίμηση του κινδύνου, τον φόβο, την πρόσβαση σε ειδικούς, έως τις μεγαλύτερες περιόδους αναμονής στα δημόσια συστήματα υγείας. Ταυτόχρονα, τα σύγχρονα smartphone είναι πανταχού παρόντα και πάντα σε ετοιμότητα. Η συχνή παρατήρηση πιθανών βλαβών που προκαλούν ανησυχία, σε συνδυασμό με την εύκολη πρόσβαση στη φωτογράφησή τους, αντιπροσωπεί μια βιώσιμη ευκαιρία για εφαρμογές. Τέτοιες εφαρμογές μπορούν να οδηγήσουν σε προσοχή χρηστών για το δέρμα τους και θα αναζητήσουν ιατρική συμβουλή νωρίτερα από ό,τι θα έκαναν διαφορετικά.

Μια προσέγγιση είναι η χρήση μοντέλων μηχανικής μάθησης για την αξιολόγηση εικόνων δερματικών βλαβών και την παροχή πρόβλεψης για την εκτίμηση του κινδύνου κακοήθειας. Στο πλαίσιο της ακαδημαϊκής κλινικής έρευνας, έχουν χρησιμοποιηθεί υψηλής απόδοσης βαθιά νευρωνικά δίκτυα που σε πειραματικά περιβάλλοντα έχουν συγκρίσιμη απόδοση με αυτήν των ειδικών. Ωστόσο, η άμεση μεταφορά ενός τέτοιου μοντέλου σε μια εφαρμογή για καταναλωτές δεν είναι χωρίς δυσκολίες. Τα μοντέλα πρόβλεψης κλινικού κινδύνου είναι συχνά μεγάλα και εξειδικευμένα σε κλινικές εικόνες που έχουν επιμεληθεί με μεγάλη προσοχή, οι οποίες δεν μοιάζουν καθόλου με τις φωτογραφικές αποτυπώσεις των στιγμάτων που λαμβάνονται από μη ειδικούς χρήστες με τις κάμερες των κινητών τηλεφώνων.

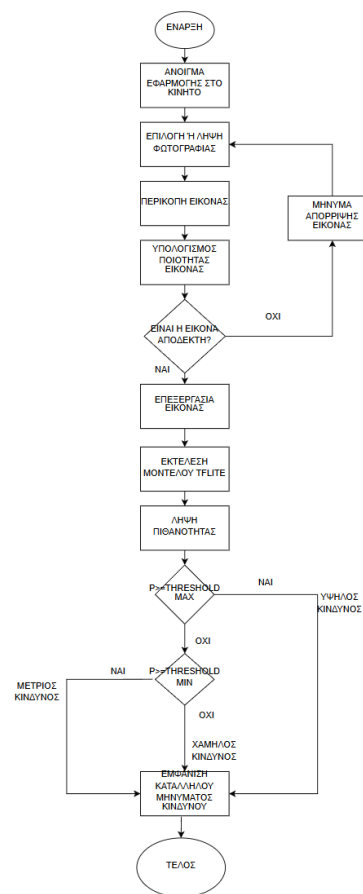
Οι εικόνες που τραβήχτηκαν σε φυσικό περιβάλλον και εκτός κλινικού πλαισίου αποτελούν επιπλέον προκλήσεις για την αξιοπιστία. Μπορεί να είναι θολές, κακώς φωτισμένες ή να παρουσιάζουν σκιές ή αντανάκλαση, ενώ μπορεί να υπάρχουν ταυτόχρονα και άλλες πολλαπλές βλάβες στο ίδιο πλαίσιο εικόνας, πέραν των πιθανών τεχνητών στοιχείων, όπως εκτεθειμένες τρίχες ή άκρα ρούχων. Όταν το μοντέλο εφαρμόζεται χωρίς αυστηρούς περιορισμούς χρήσης και επαναληπτικά σε επακόλουθες φωτογραφικές τεκμηριώσεις της ίδιας βλάβης και δεν ανακαλεί εσφαλμένες προβλέψεις όταν οι εικόνες δεν συμμορφώνονται με τα πρότυπα που έχει μάθει και που σχετίζονται με τις αξιολογήσεις ταξινόμησης κινδύνου, υπάρχει ο κίνδυνος ο αλγόριθμος να παραμείνει είτε υπερβολικά είτε ανεπαρκώς σίγουρος. Επομένως, πρέπει να δημιουργήσουμε ένα σύστημα που να έχει ένα αποδεκτό επίπεδο τεχνικής αξιοπιστίας.

Ωστόσο, υπάρχει και μια δεύτερη πρόκληση που πρέπει να αντιμετωπιστεί και αφορά τις περιγραφές κατά την επικοινωνία των αποτελεσμάτων του μοντέλου στην τελική ανάλυση, έτσι ώστε οι πληροφορίες σχετικά με τον κίνδυνο να γίνονται κατανοητές από τον χρήστη, σε αντίθεση με τυχόν πιθανές ιατρικές/προγνωστικές διαγνώσεις. Δυστυχώς, η βάση κλινικών στοιχείων είναι περιορισμένη και, ως εκ τούτου, οι σχετικές κανονιστικές διατάξεις, τα επαγγελματικά πεδία εφαρμογής και τα

Εισαγωγή

πρότυπα είτε δεν είναι αρκετά σαφή. Παρ' όλα αυτά, για το συνολικό αποτέλεσμα οποιουδήποτε μοντέλου που λαμβάνει υπόψη την ασφάλεια, την ευθύνη, την αποκάλυψη και τη συγκατάθεση μετά από ενημέρωση, τα υποκείμενα μοντέλα δεν μπορούν να διατρέχουν τον κίνδυνο να εφαρμοστούν με τρόπους που δεν επιτυγχάνουν επαρκή ανθεκτικότητα σε μια διαχειρίσιμη πλατφόρμα.

Όσον αφορά τον σκοπό της εργασίας μου για εφαρμογές υποστήριξης λήψης αποφάσεων που χρησιμοποιούν μηχανική μάθηση και έχουν σχεδιαστεί προσεκτικά με βάση θέματα ασφάλειας που επικεντρώνονται στον άνθρωπο. Το ερευνητικό πλαίσιο περιλαμβάνει την εισαγωγή μοντέλων αξιολόγησης κινδύνου για καλοήθειες/κακοήθειες δερματικές βλάβες που προέρχονται από ένα επιμελημένο σύνολο δεδομένων δερματοσκοπικών εικόνων δερματικών βλαβών που εξάγονται στο TensorFlow Lite, συσκευασμένα σε μια εφαρμογή για κινητά που παρέχει ενδείξεις κινδύνου με ισχυρές δηλώσεις αποποίησης ευθύνης. Η συνολική ροή της εφαρμογής φαίνεται στο σχήμα 1.1.



Σχήμα 1.1: Διάγραμμα ροής εφαρμογής από υποβολή εικόνας μέχρι την ολοκλήρωση της απόφασης

1.2 Περιγραφή του προβλήματος και πεδίο εφαρμογής.

Το βασικό ερευνητικό ερώτημα που εξετάζεται είναι πώς να δημιουργηθεί μια ολοκληρωμένη διαδικασία που να μπορεί να διακρίνει με ακρίβεια μεταξύ καλοήθων και κακοήθων δερματικών βλαβών από δερματοσκοπικές εικόνες. Επιπλέον πρέπει να διατηρεί όσο το δυνατόν μεγαλύτερη ανθεκτικότητα στις συνήθεις ατέλειες που μπορεί να συναντηθούν στην πραγματική χρήση και να υλοποιείται σε smartphone ως ένα αποτελεσματικό μοντέλο TensorFlow Lite ενσωματωμένο σε μια

εφαρμογή για κινητά, όπου το αποτέλεσμα προσφέρεται ως πληροφορία κινδύνου και όχι ως διαγνωστική γνώμη.

Αρχικά, τίθεται το ερώτημα του πώς μπορεί να διατυπωθεί καταλληλότερα η εργασία ως πρόβλημα δυαδικής ταξινόμησης. Ορισμένες διαγνωστικές κατηγορίες του σύνολου δεδομένων HAM10000 συγχωνεύθηκαν σε καλοήθειες και κακοήθειες κατηγορίες και ο στόχος είναι να μεγιστοποιηθεί η ευαισθησία στις κακοήθειες βλάβες. Η δεύτερη πτυχή της εργασίας σχετίζεται με την ανθεκτικότητα: η διαδικασία εκπαίδευσης έχει αναπτυχθεί για να προάγει μεγαλύτερη ανοχή σε ρεαλιστικά τεχνητά στοιχεία. Για να αντικατοπτρίζονται οι τύποι των καταστάσεων που μπορεί να παρατηρηθούν στις φωτογραφίες των χρηστών, οι εικόνες υποβάλλονται σε εκτεταμένες τεχνικές αύξησης δεδομένων ώστε να προσομοιωθούν ρεαλιστικές συνθήκες λήψης. Συνοψίζοντας, δεν επιδιώκεται η κάλυψη κάθε πιθανής πραγματικής περίπτωσης, αλλά αναμένουμε να αυξήσουμε την ανοχή του μοντέλου στη μεταβλητότητα από τις ιδανικές δερματοσκοπικές εικόνες.

Η τρίτη πτυχή της εργασίας αφορά την ανάπτυξη: το εκπαιδευμένο δίκτυο εξάγεται στο TensorFlow Lite για χρήση σε συσκευές ως μέρος μιας εφαρμογής για κινητά με βάση το Flutter. Το μοντέλο δίνει μια συνεχή πιθανότητα κακοήθειας που δεν παρουσιάζεται άμεσα στον χρήστη. Αντίθετα, η πιθανότητα αντιστοιχίζεται σε ποιοτικά επίπεδα κινδύνου (για παράδειγμα, χαμηλότερος, αβέβαιος ή υψηλότερος κίνδυνος) μαζί με προλογικό κείμενο για να επικοινωνήσει σαφείς εξηγήσεις και ρητές συμβουλές για να επισκεφθείτε έναν ιατρικό εμπειρογνώμονα για τυχόν δυνητικά κακοήθειες ή μεταβαλλόμενες βλάβες.

1.3 Στόχοι και συνεισφορές

Η παρούσα διπλωματική εργασία εξετάζει τρεις κύριους στόχους που προκύπτουν από τη διατύπωση του προβλήματος:

- Η κατασκευή ενός ισχυρού αγωγού εκπαίδευσης αγωγού για ένα μοντέλο βαθιάς μάθησης που προβλέπει τον κίνδυνο κακοήθειας από δερματοσκοπικές εικόνες δερματικών βλαβών, λαμβάνοντας ειδικά υπόψη την ανισορροπία των κατηγοριών.
- Να καθοριστούν και να αξιολογηθούν τα όρια λήψης αποφάσεων και οι ζώνες κινδύνου στην έξοδο του μοντέλου, με ιδιαίτερη έμφαση στην ασφάλεια, περιορίζοντας κυρίως τον αριθμό των κακοήθων βλαβών που κατατάσσονται στην κατηγορία χαμηλού κινδύνου.
- Η τοποθέτηση του εκπαιδευμένου μοντέλου σε μια εφαρμογή για κινητά που περιλαμβάνει βασικούς ελέγχους ποιότητας εικόνας, παραδίδοντας στην συσκευή δείκτες κινδύνου μέσω TensorFlow Lite.

Αυτοί οι στόχοι έχουν ως αποτέλεσμα συγκεκριμένες συνεισφορές. Πρώτον, η εφαρμογή χρησιμοποιεί ένα μοντέλο deep learning με βάση το ConvNeXt-Tiny και κεφαλή ταξινόμησης πλήρως συνδεδεμένων επιπέδων, το οποίο έχει εκπαιδευτεί σε μια τροποποιημένη έκδοση του σύνολου δεδομένων HAM10000, στο οποίο οι αρχικές διαγνωστικές ετικέτες αντιστοιχίζονται σε κατηγορίες καλοήθων και κακοήθων βλαβών. Η ανισορροπία των κατηγοριών αντιμετωπίζεται με υπερδειγματοληψία κακοήθων περιπτώσεων και χρήση απώλειας στάθμισης ανά κατηγορία, ενώ παράλληλα παρακολουθείται η απόδοση του μοντέλου με βάση εφαρμόσιμες μετρήσεις, όπως ευαισθησία και ειδικότητα, συμπεριλαμβανομένης της περιοχής κάτω από την καμπύλη ROC.

Δεύτερον, η εφαρμογή περιγράφει λεπτομερώς μια συστηματική ανάλυση κατωφλίου και ζώνης κινδύνου που πραγματοποιείται στα αποτελέσματα του μοντέλου TensorFlow Lite. Η πρόβλεψη στο σύνολο επικύρωσης πραγματοποιείται με διαφορετικές τιμές κατωφλίου απόφασης για να διερευνηθούν οι πιθανές αντισταθμίσεις μεταξύ ευαισθησίας και ειδικότητας και χρησιμοποιείται για την επιλογή

σημείων λειτουργίας που δίνουν προτεραιότητα στην υψηλή ευαισθησία σε κακοήθεις βλάβες για τον καθορισμό ζωνών χαμηλού, μεσαίου και υψηλού κινδύνου, οι οποίες δημιουργήθηκαν υπό περιορισμούς του ποσοστού κακοήθων βλαβών στη ζώνη χαμηλού κινδύνου, με βάση τον σχεδιασμό που δίνει προτεραιότητα στην ασφάλεια.

Η τελική συμβολή που περιγράφεται προτείνει την επίδειξη της ενσωμάτωσης του προκύπτοντος μοντέλου TensorFlow Lite σε μια εφαρμογή για κινητά που αναπτύχθηκε χρησιμοποιώντας το Flutter. Η εφαρμογή για κινητά καθοδηγεί τον χρήστη στη διαδικασία λήψης και περικοπής εικόνων, εκτελεί απλές αξιολογήσεις ποιότητας εικόνας (ευκρίνεια και κάλυψη του δέρματος) και εκτελεί συμπεράσματα στη συσκευή. Τα τελικά αποτελέσματα της στρατηγικής για κινητά είναι δείκτες κινδύνου (όχι διάγνωση) με ισχυρές προειδοποιήσεις σε μορφή κειμένου και δηλώσεις αποποίησης ευθύνης ότι η εφαρμογή δεν έχει κλινικά επικυρωθεί και λειτουργεί αποκλειστικώς εργαλείο ενημέρωσης και εκτίμησης.

Συνολικά, αυτές οι συνεισφορές παρέχουν μια πλήρη επίδειξη ολόκληρης της πορείας από το στάδιο του σχεδιασμού του συνόλου δεδομένων και του μοντέλου, έως την πρώτη διεπαφή με κινητά και την ένδειξη κινδύνου. Το σύστημα που αναπτύσσεται στο πλαίσιο της διπλωματικής εργασίας δεν έχει επικυρωθεί κλινικά και ούτε παρέχεται ως ιατρική διάγνωση σε ασθενείς. Η εφαρμογή λειτουργεί αποκλειστικά ως εργαλείο ενημέρωσης και εκτίμησης κίνδυνου και όχι ως αξιολόγηση από επαγγελματία γιατρό.

1.4 Δομή

Το υπόλοιπο της διατριβής οργανώνεται σε εννέα κεφάλαια από το Κεφάλαιο 2 έως το Κεφάλαιο 8. Το κεφάλαιο 2, με τίτλο «Ιστορικό και σχετικές εργασίες», παρέχει το απαραίτητο ιστορικό για τον καρκίνο του δέρματος και τη δερματοσκοπική απεικόνιση, εξετάζει μοντέλα βαθιάς μάθησης για την ταξινόμηση εικόνων και ανασκοπεί προηγούμενες εργασίες που σχετίζονται με την αυτοματοποιημένη ανάλυση δερματικών βλαβών και συζητά τις ηθικές και κανονιστικές επιπτώσεις των εργαλείων που διαχειρίζονται ιατρικές πληροφορίες.

Το κεφάλαιο 3, με τίτλο «Σύνολο δεδομένων και προεπεξεργασία», εξετάζει το σύνολο δεδομένων που συμπληρώθηκε, περιγράφοντας λεπτομερώς τον τρόπο με τον οποίο οι αρχικές διαγνωστικές ετικέτες για τις βλάβες στο σύνολο δεδομένων μειώνονται σε ένα δυαδικό αποτέλεσμα μεταξύ καλοήθους και κακοήθους. Το κεφάλαιο 3 περιγράφει τον τρόπο με τον οποίο τα δεδομένα θα χωριστούν σε σύνολα εκπαίδευσης και επικύρωσης, στη συνέχεια περιγράφει τη διαδικασία προεπεξεργασίας που εκτελείται στα δεδομένα εικόνας και περιγράφει τις τεχνικές επαύξησης δεδομένων για να διασφαλιστεί η μεγιστοποίηση της ανθεκτικότητας του μοντέλου για πραγματικά αντικείμενα.

Το Κεφάλαιο 4, με τίτλο «Αρχιτεκτονική μοντέλου και διαδικασία εκπαίδευσης», περιγράφει λεπτομερώς την αρχιτεκτονική του μοντέλου βαθιάς μάθησης (με βάση το ConvNeXt-Tiny) με την προσθήκη μηχανισμών προσοχής καναλιού και τον σχεδιασμό της κεφαλής ταξινόμησης. Στη συνέχεια, το κεφάλαιο περιγράφει τη διαδικασία εκπαίδευσης, συμπεριλαμβανομένων των δυσκολιών που σχετίζονται με τα βάρη των κλάσεων, τις ρυθμίσεις που σχετίζονται με τον βελτιστοποιητή, τις προσαρμοσμένες μετρήσεις αξιολόγησης και τη διαδικασία πρόωρης διακοπής.

Το Κεφάλαιο 5, με τίτλο «Αξιολόγηση και επιλογή ορίου», παρουσιάζει τα ευρήματα σχετικά με τις μετρήσεις απόδοσης στο σύνολο επικύρωσης και συζητά τις συμβιβαστικές λύσεις μεταξύ ευαισθησίας και ειδικότητας για διάφορα όρια. Αυτό το κεφάλαιο περιγράφει τη διαδικασία για τον καθορισμό ζωνών χαμηλού, μέτριου και υψηλού κινδύνου χρησιμοποιώντας την έξοδο της πιθανότητας του

μοντέλου και περιλαμβάνει μια ανασκόπηση του τρόπου με τον οποίο το σύστημα περιόρισε το ποσοστό των κακοήθων περιπτώσεων στην κατηγορία χαμηλού κινδύνου.

Το Κεφάλαιο 6, με τίτλο «Εξαγωγή μοντέλου και ενσωμάτωση σε εφαρμογή για κινητά», περιγράφει τις διαδικασίες που εξηγούν τον τρόπο εξαγωγής του εκπαιδευμένου μοντέλου σε διάφορες παραλλαγές του TensorFlow Lite. Επιπλέον παρουσιάζεται ο τρόπος αποθήκευσης και απόδοσης των εκτιμήσεων κίνδυνου καθώς και οι έλεγχοι ποιότητας εικόνων και ο σχεδιασμός διαπαφής. Το Κεφάλαιο 6 παρέχει μια περιγραφή των ελέγχων ποιότητας εικόνων και του σχεδιασμού της διεπαφής χρήστη που χρησιμοποιείται για τη μεταφορά πληροφοριών κινδύνου στον χρήστη.

Το Κεφάλαιο 7, με τίτλο «Συζήτηση και ηθικές σκέψεις», ερμηνεύει τα ευρήματα στο πλαίσιο του πραγματικού κόσμου για πιθανή χρήση, συζητά τους σχετικούς περιορισμούς αυτής της προσέγγισης και περιγράφει ευρύτερες ηθικές σκέψεις για αυτό και παρόμοια συστήματα, συμπεριλαμβανομένης της ψευδούς διαβεβαίωσης, της συμπεριφοράς των συμμετεχόντων, της ιδιωτικότητας των δεδομένων και της επωνυμοποίησης των επιλογών απάντησης ως εργαλείων υποστήριξης και όχι ως διαγνωστικών.

Τέλος, το Κεφάλαιο 9, με τίτλο «Συμπέρασμα και μελλοντική εργασία», συνοψίζει τα κύρια ευρήματα και τις συνεισφορές της διατριβής, αναλύει τους περιορισμούς και το συνολικό πεδίο εφαρμογής του έργου και προσδιορίζει μελλοντικές ερευνητικές δυνατότητες, συμπεριλαμβανομένης της κλινικής επικύρωσης, της εφαρμογής πιο σύνθετων συνόλων δεδομένων και των μελετών χρηστών με σκοπό την κατανόηση της ερμηνείας των ανθρώπων που ενεργούν βάσει των πληροφοριών κινδύνου που παράγονται από τέτοιου είδους σχεδιασμούς.

Κεφάλαιο 2ο: Ανασκόπηση

Αυτό το κεφάλαιο εξετάζει και συζητά το ιστορικό πλαίσιο και τις προηγούμενες εργασίες που σχετίζονται με την εργασία. Το κεφάλαιο αυτό θα ξεκινήσει με την περιγραφή του πλαισίου του καρκίνου του δέρματος και της σημασίας της έγκαιρης διάγνωσης. Στη συνέχεια, θα εξετάσουμε τη δερματοσκοπική απεικόνιση και θα συζητήσουμε τα σύνολα δεδομένων/δείκτες που είναι δημοφιλείς περιπτώσεις χρήσης για την ανάλυση εικόνων δερματικών βλαβών. Στη συνέχεια, θα συζητήσουμε τις βασικές έννοιες για την ταξινόμηση εικόνων στη μηχανική μάθηση και το deep learning, με ιδιαίτερη έμφαση στα συνελκτικά νευρωνικά δίκτυα και τη μεταφορά μάθησης. Στη συνέχεια, θα συζητήσουμε προηγούμενα έργα σε αυτοματοποιημένα και ημιαυτοματοποιημένα συστήματα για την ταξινόμηση δερματικών βλαβών και εφαρμογές κινητής υγείας. Τέλος, θα ολοκληρώσουμε με μια συζήτηση σχετικά με σημαντικές ηθικές και κανονιστικές παραμέτρους για συστήματα που μοιράζονται ιατρικές πληροφορίες στο δημόσιο τομέα ή σε μη ειδικούς χρήστες.


2.1 Καρκίνος του δέρματος και έγκαιρη ανίχνευση

Ο καρκίνος του δέρματος ορίζεται ως η ανεξέλεγκτη ανάπτυξη ανώμαλων δερματικών κυττάρων. Οι καρκίνοι του δέρματος κατηγοριοποιούνται γενικά σε μη μελανωματικούς καρκίνους του δέρματος και μελάνωμα. Οι μη μελανωματικοί καρκίνοι του δέρματος περιλαμβάνουν το βασικοκυτταρικό καρκίνωμα (BCC) και το πλακώδες καρκίνωμα (SCC), τα οποία προέρχονται από τα κερατινοκύτταρα της επιδερμίδας. Αντίθετα, το μελάνωμα είναι μια σοβαρή μορφή καρκίνου που αναπτύσσεται από τα μελανοκύτταρα. Οι μη μελανωματικοί καρκίνοι του δέρματος είναι οι συχνότεροι τύποι δερματικού καρκίνου ενώ το μελάνωμα εμφανίζεται λιγότερο συχνά αλλά είναι σημαντικά πιο επιθετικό ως προς την υγεία του ανθρώπου. Ωστόσο, το μελάνωμα συνδέεται με αυξημένο κίνδυνο μετάστασης και υψηλότερη θνησιμότητα σε σύγκριση με άλλους τύπους καρκίνου του δέρματος. Σε ορισμένες χώρες, όπως οι ΗΠΑ, τα ποσοστά εμφάνισης μελανώματος συνεχίζουν να αυξάνονται τις τελευταίες δεκαετίες [6]. Με αυτή την αύξηση, έρχεται η γενική εστίαση στην πρόληψη και την έγκαιρη ανίχνευση των καρκίνων του δέρματος και την άμεση θεραπεία. Βάσεις δεδομένων σταδιοποίησης αποκαλύπτουν μια σαφή σύνδεση ανάμεσα στο πάχος του πρωτοπαθούς μελανώματος και την επιβίωση, αναδεικνύοντας τη σημαντική σημασία της πρώιμης διάγνωσης [7].

Ένα αξιοσημείωτο χαρακτηριστικό του μελανώματος σε σύγκριση με πολλούς άλλους καρκίνους είναι ότι μπορεί να γίνει ορατό από το άτομο που πάσχει. Πολλές από αυτές τις βλάβες γίνονται ορατές μέσω παρατηρήσιμων αλλαγών στο μέγεθος, στο σχήμα, στο χρώμα και την δομή τους. Έχουν αναπτυχθεί πολυάριθμα κλινικά κριτήρια, όπως ο δημοφιλής κανόνας ABCD [8] (ασυμμετρία, ακανόνιστο περίγραμμα, χρωματική διακύμανση και διάμετρος), για να βοηθήσουν τους κλινικούς ιατρούς και, σε μικρότερο βαθμό, τους μη ειδικούς να προσδιορίσουν τις βλάβες που ενδέχεται να απαιτούν περαιτέρω εξέταση. Ανεξάρτητα από τα κλινικά κριτήρια, η ακριβής διάγνωση εξακολουθεί να απαιτεί αξιολόγηση από ειδικό καθώς και ιστοπαθολογική επαλήθευση.

Η έγκαιρη ανίχνευση είναι απαραίτητη για την πρόγνωση. Όταν το μελάνωμα είναι εξαιρετικά λεπτό και εξακολουθεί να περιορίζεται στην επιδερμίδα, η χειρουργική εκτομή είναι πολύ αποτελεσματική και το ποσοστό επιβίωσης είναι πολύ υψηλότερο από ό,τι στα μεταγενέστερα στάδια. Όταν ανιχνεύεται αργά, ο ασθενής μπορεί να υποστεί βαθύτερη εισβολή και τελικά εξάπλωση, με αποτέλεσμα σημαντικά χειρότερα κλινικά αποτελέσματα και μειωμένα ποσοστά επιβίωσης [5,7]. Ταυτόχρονα, η ευαισθητοποίηση του κοινού σχετικά με το μελάνωμα και η πρόσβαση σε δερματολογικές υπηρεσίες ποικίλλουν σε μεγάλο βαθμό και πολλά άτομα δεν αναγνωρίζουν νέες ή μεταβαλλόμενες βλάβες ή δεν

εκτιμούν τη σημασία τους. Αυτή η ασυμφωνία μεταξύ της ορατότητας της νόσου και της πραγματικότητας της πρόσβασης σε κλινική περίθαλψη υποστηρίζει τις προσπάθειες για την αξιοποίηση εργαλείων που θα μπορούσαν να προωθήσουν το κοινό να αναζητήσει ιατρική βοήθεια για αναδυόμενες ή ύποπτες βλάβες. Για την καλύτερη κατανόηση της ποικιλίας δερματικών βλαβών, παρουσιάζονται στο σχήμα 2.1 κάποια παραδείγματα μεταξύ καλοήθων και κακοήθων βλαβών από τα δεδομένα HAM10000.



Σχήμα 2.1: Ενδεικτικά παραδείγματα καλοήθων και κακοήθων δερματικών βλαβών από το σύνολο δεδομένων HAM10000.

2.2 Δερματοσκοπική απεικόνιση και σύνολα δεδομένων

Η δερματοσκόπηση, γνωστή και ως μικροσκοπία επιφάνεια, είναι μια μη επεμβατική μέθοδος απεικόνισης που χρησιμοποιεί μεγέθυνση και πολωμένο ή μη πολωμένο φωτισμό, η οποία διευκολύνει την οπτικοποίηση των δομών εντός της επιδερμίδας και του επιφανειακού χωρίου. Η δερματοσκόπηση έχει δείξει ότι βελτιώνει σημαντικά την ακρίβεια στη διάγνωση των χρωματισμένων βλαβών σε σχέση με την απλή κλινική εξέταση [9]. Η δερματοσκόπηση, σε σύγκριση με την εξέταση με γυμνό μάτι, δείχνει μοτίβα, χρώματα και δομές που διαφορετικά δεν θα ήταν ορατά και έχει πλέον καταστεί η μέθοδος επιλογής στη δερματολογία για την αξιολόγηση ύποπτων χρωματικών βλαβών. Οι τυπικές δερματοσκοπικές εικόνες λαμβάνονται και δείχνουν τη βλάβη σε επαρκή ανάλυση (δηλ. υψηλή) και είναι συνήθως κεντροθετημένες στο πλαίσιο, με ελεγχόμενο φωτισμό και καθαρό και ελάχιστο φόντο. Τα μεγάλα σύνολα δεδομένων δερματοσκοπικών εικόνων έχουν αποτελέσει αναπόσπαστο μέρος της ανάπτυξης μεθόδων μηχανικής μάθησης για την ανάλυση και ταξινόμηση δερματικών βλαβών τα τελευταία δέκα χρόνια. Τα σχήματα για δημόσιες βιβλιοθήκες εικόνων έχουν επιτρέψει στους ερευνητές να αξιολογήσουν αλγόριθμους για το σκοπό αυτό και να διευκολύνουν τη συγκριτική απόδοση. Το σύνολο δεδομένων HAM10000 είναι ένα από τα πιο χρησιμοποιούμενα. Το HAM10000 περιλαμβάνει δερματοσκοπικές εικόνες βλαβών που έχουν ταξινομηθεί σε διαγνωστικές κατηγορίες: μελανοκυτταρικά σπύλα, μελάνωμα, καλοήθεις βλάβες τύπου κεράτωσης, βασικοκυτταρικό καρκίνωμα, ακτινικές κερατώσεις και ενδοεπιθηλιακά καρκινώματα, δερματοίνωμα και αγγειακές βλάβες. Ενδεικτικές εικόνες βρίσκονται στο Σχήμα 2.1.

Αυτά τα σύνολα δεδομένων προήλθαν από κλινικές λήψεις και, ως εκ τούτου, οι συνθήκες ελέγχθηκαν με συσκευές και πρωτόκολλα απεικόνισης. Τα σύνολα δεδομένων αποτελούν μια εξαιρετική βάση για έναν αλγόριθμο, αλλά εξακολουθούν να υπάρχουν πολλές σημαντικές διαφορές μεταξύ των δερματοσκοπικών εικόνων βλαβών και των εικόνων που λαμβάνονται από μη ειδικούς χρήστες που λαμβάνουν εικόνες με καταναλωτικά smartphone. Οι δερματοσκοπικές εικόνες μπορεί να απεικονίζουν τη βλάβη σε ένα ομοιόμορφο φόντο και μεμονωμένα ή να περιλαμβάνουν όλες τις βλάβες και περιοχές

διαφορετικής υφής μαζί με αντικείμενα του φόντου, όπως περιοχές με τρίχες του σώματος και είδη ρουχισμού ή κοσμήματα. Αυτές είναι σημαντικές διαφορές που πρέπει να ληφθούν υπόψη κατά την αξιολόγηση της απόδοσης μοντέλου όταν χρησιμοποιούνται δερματοσκοπικά δεδομένα εκπαίδευσης που στη συνέχεια αποδίδονται σε ένα λιγότερο ελεγχόμενο περιβάλλον.



[1] Εικόνα Καταναλωτή

[2] Δερματοσκοπική εικόνα

Σχήμα 2.2: Σύγκριση εικόνας καταναλωτή με δερματοσκοπική εικόνα.

Οι παραπάνω εικόνες δείχνουν διαφορές μεταξύ καταναλωτών και δερματοσκοπικών εικόνων. Αυτό επηρέασε σημαντικά τον σχεδιασμό του παρόντος συστήματος στον τομέα αύξησης δεδομένων και αξιολόγηση του μοντέλου.

2.3 Μηχανική μάθηση και βαθιά μάθηση για την ταξινόμηση εικόνων

Η μηχανική μάθηση είναι μια ομάδα μεθόδων που επιτρέπει σε έναν υπολογιστή να μαθαίνει μοτίβα από δεδομένα και στη συνέχεια να προβλέπει αποτελέσματα, χωρίς να έχει προγραμματιστεί να το κάνει για κάθε παράδειγμα. Για παράδειγμα, στην εποπτευόμενη μάθηση υπάρχουν επισημασμένα παραδείγματα εικόνων και ένα μοντέλο μαθαίνει πώς η επισημασμένη κατάσταση σχετίζεται με τα δεδομένα της εικόνας εισόδου από αυτό το παράδειγμα. Η ταξινόμηση εικόνων είναι μια τυπική εποπτευόμενη εργασία μάθησης, καθώς απαιτεί μια εικόνα ως είσοδο και παράγει μια ετικέτα κλάσης ως έξοδο, όπως στην περίπτωση δυαδικής ταξινόμησης καλοήθους ή κακοήθους βλάβης.

Οι μέθοδοι βαθιάς μάθησης, ιδίως τα συνελκτικά νευρωνικά δίκτυα, έχουν αλλάξει τα δεδομένα στην ταξινόμηση εικόνων, επειδή λαμβάνουν την εικόνα εισόδου και εφαρμόζουν εκπαιδευόμενα φίλτρα σε χωρικές γειτονιές της εικόνας για να ανιχνεύσουν και να ταξινομήσουν τοπικά μοτίβα, όπως άκρα, υφές και σχήματα, τα οποία στη συνέχεια συνδυάζονται σε αναπαραστάσεις υψηλότερου επιπέδου. Τα συνελκτικά νευρωνικά δίκτυα αποτελούν μέρος της ευρύτερης κατηγορίας της βαθιάς μάθησης, η οποία έχει επιφέρει σημαντικές αλλαγές στην επεξεργασία εικόνας και σε πολλά ακόμα πεδία τα τελευταία χρόνια [11]. Αποδεδειγμένες αρχιτεκτονικές, όπως VGG, ResNet, Inception, DenseNet και, πιο πρόσφατα, ConvnNeXt, έχουν επιτύχει αποτελέσματα τελευταίας τεχνολογίας σε μεγάλα σύνολα δεδομένων αναφοράς, όπως το ImageNet, και έχουν προσαρμοστεί με επιτυχία σε εφαρμογές ιατρικής απεικόνισης, όπως η ανίχνευση δερματικών βλαβών, όπου τα σχολιασμένα δεδομένα είναι πιο περιορισμένα και οι εικόνες διαφέρουν σημαντικά από φυσικές φωτογραφίες γενικής χρήσης. Αυτές οι αρχιτεκτονικές έχουν αναλυθεί και αξιολογηθεί λεπτομερώς στη βιβλιογραφία της υπολογιστικής όρασης, αποτελώντας τα θεμέλια για πολλές εφαρμογές στον τομέα της ιατρικής απεικόνισης [12].

2.4 Αυτοματοποιημένη ανάλυση δερματικών βλαβών.

Η υπολογιστικά υποβοηθούμενη ανάλυση εικόνων δερματικών βλαβών είναι ένας τομέας έρευνας με εκτενή βιβλιογραφία και μακρά ερευνητική δραστηριότητα. Παλαιότερα, η αυτοματοποιημένη ανάλυση περιελάμβανε ένα σύνολο χειροκίνητα εξαγομένων χαρακτηριστικών σχεδιασμένων από ειδικούς για να καταγράφουν τις πολλαπλές παραλλαγές των βλαβών και τροφοδοτούσαν έναν

παραδοσιακό ταξινομητή. Μερικά κοινά χαρακτηριστικά είναι οι μετρήσεις χρωματικού ιστογράμματος, οι μετρήσεις ακανόνιστων ορίων, οι περιγραφές σχήματος και οι μετρήσεις υφής που χρησιμοποιούνται σε παραδοσιακούς μηχανισμούς ταξινόμησης, όπως μηχανές υποστήριξης διανυσμάτων ή k-πλησιέστεροι γείτονες. Αν και υπήρχαν ορισμένα κλινικά κίνητρα για την καταγραφή των βλαβών, η απόδοση περιοριζόταν σε προσεκτικά σχεδιασμένα χαρακτηριστικά και στην αστάθεια του θορύβου και των συνθηκών κατά τη λήψη της εικόνας.

Από την ανάπτυξη των μοντέλων βαθιάς μάθησης, η έρευνα έχει στραφεί προς την χρήση συνεκτικών αρχιτεκτονικών που μαθαίνουν χαρακτηριστικά απευθείας από τις εικόνες εισόδου, έτσι ώστε το μοντέλο να μαθαίνει χαρακτηριστικά απευθείας μόνο από την εισαγωγή εικόνων. Μελέτες έχουν δείξει ότι τα βαθιά δίκτυα μπορούν να παρέχουν ένα μεγάλο ποσοστό ακρίβειας και να βελτιώνουν σημαντικά την απόδοση για την ταξινόμηση των κακοήθων και καλοήθων βλαβών σε δερματοσκοπικά σύνολα δεδομένων. Σε αρκετές έρευνες, τα συνελκτικά νευρωνικά δίκτυα έχουν παρουσιάσει συγκρίσιμη απόδοση με ομάδες σε ελεγχόμενα πειραματικά πρωτοκολλά με βάση την ανίχνευση μελανώματος μέσω δερματοσκοπικών εικόνων πετυχαίνοντας υψηλές τιμές ευαισθησίας καθώς και AUC (>0.85) στην δυαδική διάκριση των εικόνων[13].

Αν και έχουν υπάρξει θετικά αποτελέσματα από ένα επιμελημένο σύνολο δεδομένων, υπάρχουν άλλα εμπόδια πριν από την επιτυχία αυτών των μοντέλων σε ισχυρά και κερδοφόρα εργαλεία που εισάγονται στους δερματολόγους. Υπάρχουν πολλά εμπόδια για τα ισχυρά μοντέλα τα οποία προηγούμενες μελέτες έχουν δοκιμάσει μόνο ποσοτικά. Το πρώτο είναι η ανθεκτικότητα, ένα μοντέλο που έχει εκπαιδευτεί σε δερματοσκοπικές εικόνες, θα παρουσιάσει κάποιο βαθμό ευαισθησίας σε οπτικές γωνίες, φωτισμό, εστίαση ή άλλα ορατά τεχνητά στοιχεία όπως τρίχες και φυσαλίδες. Η προσομοίωση της αύξησης των δεδομένων σε όλα αυτά τα στοιχεία μπορεί να βοηθήσει στην επίτευξη αυτού του στόχου, αλλά δεν θα εγγυηθεί την ανθεκτικότητα σε όλες τις παραλλαγές.

Υπάρχει επίσης ένα ερώτημα σχετικά με τη συγκεκριμένη βαθμονόμηση του μοντέλου στην οποία οι προβλεπόμενες πιθανότητες αντανakλούν την πραγματική συχνότητα κακοήθειας. Η ικανότητα του μοντέλου να διαφοροποιεί τις καλοήθειες από τις κακοήθειες βλάβες είναι εξαιρετική. Ωστόσο, οι αριθμητικές πιθανότητες που σχετίζονται με το μοντέλο δεν αντικατοπτρίζουν με ακρίβεια την πραγματικότητα όσον αφορά τη συχνότητα κακοήθειας. Ένας χρήστης αυτού του μοντέλου θα μπορούσε να υπερεκτιμήσει ή να υποεκτιμήσει τον κίνδυνο λόγω της έλλειψης αντιστοιχίας μεταξύ των αριθμητικών πιθανοτήτων του μοντέλου και της πραγματικής συχνότητας κακοήθειας. Επομένως, οι ζώνες κινδύνου και τα όρια πιθανότητας που χρησιμοποιούνται σε αυτή την εφαρμογή θα πρέπει να βασίζονται σε προσεκτική εξέταση των δεδομένων επικύρωσης με σαφή τεκμηρίωση σχετικά με τον τρόπο υπολογισμού των τιμών.

2.5 Εφαρμογές κινητής υγείας και συμπεράσματα στη συσκευή

Η κινητή υγεία ορίζεται απλά ως η παροχή υπηρεσιών υγείας και πληροφοριών υγείας μέσω φορητών συσκευών, όπως smartphone και tablet με στόχο την βελτίωση της πρόληψης, διάγνωσης και παρακολούθησης εκπαιδευτικών ασθενών. Ειδικά στη δερματολογία, υπάρχουν πολλές εφαρμογές που βοηθούν στην παρακολούθηση των δερματικών στιγμάτων, στέλνουν υπενθυμίσεις για αυτοεξέταση ή παρέχουν γενικό και εκπαιδευτικό περιεχόμενο σχετικά με τον καρκίνο του δέρματος και την προστασία από τον ήλιο. Επιπλέον, ορισμένες εφαρμογές αξιολογούν αυτόματα μια βλάβη ή κατηγορία κινδύνου και προσφέρουν βαθμολογίες κινδύνου για τον χρήστη με βάση μια εικόνα που έχει τραβήξει ο ασθενής. Συστηματικές ανασκοπήσεις έχουν αποκαλύψει ότι αυτές οι εφαρμογές εμφανίζουν σημαντικές αποκλίσεις στην ακρίβεια, γεγονός που μπορεί να θέσει σε κίνδυνο τους χρήστες με ψευδείς διαβεβαιώσεις [14]. Είναι επίσης σημαντικό να σημειωθεί ότι υπάρχουν πλεονεκτήματα στη λειτουργία ενός μοντέλου μηχανικής μάθησης στη συσκευή. Η κινητή συσκευή προσφέρει χαμηλότερη καθυστέρηση και βασική λειτουργικότητα ακόμα και σε περίπτωση απουσίας σύνδεσης δικτύου. Η συσκευή μπορεί επίσης να ενισχύσει την προστασία των προσωπικών δεδομένων, καθώς οι εικόνες δεν μεταφορτώνονται ποτέ σε απομακρυσμένο διακομιστή. Στη βιβλιογραφία, η εφαρμογή μοντέλων

μηχανικής μάθησης εντός της συσκευής αναγνωρίζεται ως σημαντική στρατηγική για τη μείωση των κινδύνων διαρροής πληροφοριών και για καλύτερη συμμόρφωση με τους κανονισμούς προστασίας προσωπικών δεδομένων [23]. Υπάρχουν καθιερωμένα πλαίσια, όπως το TensorFlow Lite, που επιτρέπουν την ανάπτυξη εκπαιδευμένων μοντέλων σε συσκευές με περιορισμένους πόρους με βελτιστοποιήσεις όπως κβαντοποίηση ή μειωμένο μέγεθος μοντέλου, ενδεχομένως με θυσία της ακρίβειας. Ωστόσο, υπάρχουν πολλές επιπλέον σχεδιαστικές παράμετροι που πρέπει να ληφθούν υπόψη κατά τη δημιουργία ενός συστήματος για την ανάπτυξη εφαρμογών που χρησιμοποιούν μηχανική μάθηση στην καθημερινή πρακτική. Η διεπαφή χρήστη πρέπει να είναι φιλική προς τον χρήστη και απλή, ώστε να ακολουθεί τις εργασίες που θα κάνει ο χρήστης (όπως η λήψη μιας εικόνας και η περικοπή της), και η ανατροφοδότηση του συστήματος πρέπει να παρέχεται με τρόπο που να επικοινωνεί ακριβείς πληροφορίες και να μην ενθαρρύνει τον χρήστη να ερμηνεύσει λανθασμένα τον κίνδυνο ή τη βαθμολογία του. Για παράδειγμα, μια αριθμητική πιθανότητα μπορεί να φαίνεται πιο ακριβής από ό,τι είναι στην πραγματικότητα και μπορεί να μετατραπεί σε μια λανθασμένη και οριστική κρίση. Αυτός είναι ο λόγος για τον οποίο πολλά σχέδια προτιμούν τις ποιοτικές κατηγορίες και παρέχουν κάποια αναγνώριση της αβεβαιότητας, αν χρειαστεί, μαζί με σαφείς προτάσεις για την επίσκεψη σε επαγγελματία σε ορισμένες περιπτώσεις. Υπάρχουν συστήματα πρώιμα όπως είναι το m-Skin Doctor που εφάρμοσαν συνελκτικά δίκτυα σε δερματοσκοπικές εικόνες παρέχοντας εκτιμήσεις κινδύνου αυτόματα [4]. Οι παράγοντες που ειπωθήκαν παραπάνω οδήγησαν στην επιλογή συμπερασμάτων κατευθείαν στη συσκευή με την χρήση του TFLite, ώστε να επιτευχθεί χαμηλή καθυστέρηση και προστασία ιδιωτικότητας.

2.6 Ηθικά και κανονιστικά ζητήματα

Κάθε σύστημα που επεξεργάζεται ιατρικά δεδομένα και παρέχει δεδομένα που ενδέχεται να επηρεάσουν τις επιλογές ενός χρήστη σε θέματα υγείας μπορεί να δημιουργήσει ηθικά διλήμματα και κανονιστικά ζητήματα σχετικά με την ασφάλεια και την ακρίβεια των παρεχόμενων πληροφοριών. Στην περίπτωση της αυτοματοποιημένης ανάλυσης δερματικών βλαβών, η πιθανή ψευδής διαβεβαίωση αποτελεί ένα από τα σημαντικότερα ηθικά προβλήματα. Η παγκόσμια βιβλιογραφία τονίζει ότι τα συστήματα τεχνητής νοημοσύνης στον τομέα της υγειονομικής περίθαλψης πρέπει να σχεδιάζονται προσεκτικά. Αυτός ο σχεδιασμός είναι σημαντικός για την αποφυγή ψευδούς αίσθησης ασφάλειας και τη συμμόρφωση με τους ισχύοντες κανονισμούς που αφορούν ιατροτεχνολογικά προϊόντα καθώς και την προστασία των δεδομένων [20]. Εάν μια εφαρμογή αξιολογήσει μια βλάβη ως «χαμηλού κινδύνου», ενώ στην πραγματικότητα είναι κακοήθης, ο χρήστης μπορεί να επιλέξει να καθυστερήσει την αναζήτηση επαγγελματικής βοήθειας. Επιπλέον, η ψευδής διαβεβαίωση μπορεί να προκύψει από υπερβολικά προσεκτικές προβλέψεις για τον κίνδυνο κακοήθειας, και η ανησυχία αυτή νδέχεται να οδηγήσει σε περιττές ιατρικές διαβουλεύσεις. Επομένως, η ικανότητα εξισορρόπησης της ευαισθησίας και της ειδικότητας δεν είναι μόνο ένα ζήτημα τεχνικής βελτιστοποίησης, περιορισμός, αλλά και μια σημαντική ευθύνη όσον αφορά την επικοινωνία του κινδύνου.

Ένα άλλο ζήτημα είναι η διαφάνεια σχετικά με τους περιορισμούς που επιβάλλονται στο σύστημα. Οι χρήστες πρέπει να γνωρίζουν ότι η εφαρμογή δεν αποτελεί υποκατάστατο επαγγελματικής ιατρικής διάγνωσης και ότι ούτε αυτή, ούτε σε καμία περίπτωση, θα παρέχει πληροφορίες που να υποδηλώνουν στον χρήστη ότι δεν υπάρχει πιθανότητα ασθένειας. Η συμπερίληψη σαφών δηλώσεων αποποίησης ευθύνης σχετικά με τους περιορισμούς, η συνεπής διατύπωση και η καθοδήγηση είναι βασικά χαρακτηριστικά ενός ηθικά υπεύθυνου σχεδιασμού, ενώ η καθοδήγηση σχετικά με το χρόνο που πρέπει να συμβουλευτείτε έναν κλινικό γιατρό στο σύστημα είναι εξίσου σημαντική, καθώς οι πιθανές συνέπειες της καθυστέρησης της έγκαιρης επαγγελματικής αξιολόγησης μπορεί να είναι πολύ σοβαρές.

Επίσης, πρέπει να ληφθεί υπόψη το ζήτημα της προστασίας των δεδομένων προσωπικού χαρακτήρα. Οι εικόνες δερματικών βλαβών και των σχετικών με την υγεία είναι ευαίσθητα προσωπικά δεδομένα και πρέπει να γίνονται σεβαστά. Για να μετριαστούν τα ζητήματα προστασίας της ιδιωτικής ζωής, η

συσκευή εκτελεί την ανάλυση και διαθέτει λειτουργικότητα επεξεργασίας εικόνων χωρίς διαμεσολαβητικό διακομιστή.

2.7 Σύγχρονα μοντέλα βαθιάς μάθησης στη δερματολογία

Εκτός από τα τυπικά συνελκτικές αρχιτεκτονικές βάσης (backbones), αναπτύσσονται όλο και περισσότερο υβριδικές και αρχιτεκτονικές βασισμένες σε μετασχηματιστές (Transformers) για την ανάλυση δερματικών βλαβών. Τα Vision Transformers (ViT) και οι ιεραρχικές παραλλαγές, όπως το Swin Transformer, αντιμετωπίζουν την εικόνα ως μια σειρά από patches και βασίζονται κυρίως σε μηχανισμούς αυτοπροσοχής και όχι σε συνελκτικές λειτουργίες. Σε θεωρητικό επίπεδο, οι μηχανισμοί αυτοπροσοχής επιτρέπουν στο μοντέλο να καταγράφει εξαρτήσεις μεγάλων αποστάσεων, οι οποίες μπορεί να είναι σημαντικές όταν υπάρχουν παγκόσμια μοτίβα που βασίζονται στη συνολική ασυμμετρία ή την κατανομή χρωμάτων. Ωστόσο, αυτά τα είδη μοντέλων τείνουν να είναι βαρύτερα και να απαιτούν περισσότερα δεδομένα από το ConVNeXt-Tiny, γεγονός που δυσχεραίνει την πρακτική εφαρμογή τους σε συσκευές με αυστηρούς περιορισμούς μνήμης και καθυστέρησης όπου οι περιορισμοί μνήμης και καθυστέρησης είναι αυστηροί.

Μια άλλη σημαντική τάση στη βιβλιογραφία είναι η εμφάνιση πολυτροπικών μοντέλων που ενσωματώνουν εισόδους εικόνων με δημογραφικές ή κλινικές πληροφορίες, όπως ηλικία, φύλο ή θέσεις βλαβών. Το σύνολο δεδομένων HAM10000 είναι ένα παράδειγμα αυτού του τύπου πρόσθετων μεταδεδωμένων. Αρκετές εργασίες αξιοποιούν τέτοιες λειτουργίες είτε με την ύπαρξη ενός κλάδου του δικτύου παράλληλου με την επεξεργασία εικόνων για τον προσδιορισμό των χαρακτηριστικών, είτε με τη συνένωση των δημογραφικών χαρακτηριστικών με ενσωματώσεις βασισμένες σε ένα μοντέλο εικόνας, παράγοντας ίση ή μέτρια βελτίωση στην απόδοση. Ωστόσο, για αυτά τα συγκεκριμένα έργα, η προσοχή εστιάζεται σκόπιμα σε ένα μοντέλο μόνο εικόνας, καθώς όταν η αλληλεπίδραση ενσωματώνεται στον αγωγό TensorFlow Lite, θα είναι λιγότερο παρεμβατική ως προς την ιδιωτικότητα και οι χρήστες δεν θα εισάγουν ρητά προσωπικά αναγνωρίσιμες πληροφορίες. Η διάκριση μεταξύ εικόνων και μεταδεδωμένων επιτρέπει επίσης την απλούστερη ενσωμάτωση στη συσκευή στο Flutter.

Μια επαναλαμβανόμενη δυσκολία κατά τη χρήση του deep learning στη δερματολογία είναι η ασυμφωνία κατανομών δεδομένων. Οι δερματοσκοπικές εικόνες τραβήχτηκαν υπό πιο ελεγχόμενες συνθήκες χρησιμοποιώντας ειδικές συσκευές, οπότε τείνουν να είναι πιο ομοιογενείς όσον αφορά τόσο τον φωτισμό όσο και τη μεγέθυνση. Οι φωτογραφίες από smartphone μπορεί να παρουσιάζουν πολύ μεγαλύτερες διακυμάνσεις που προκαλούνται από διαφορετικά μονάδες κάμερας και αλγόριθμους συμπίεσης, συνθήκες φωτισμού, τεχνητά στοιχεία όπως μαλλιά, σκιές και ακαταστασία από το φόντο. Πολλές πρόσφατες εργασίες παρουσιάζουν τρόπους μείωσης αυτού του χάσματος μεταξύ των τομέων, είτε με την ενσωμάτωση δερματοσκοπικών εικόνων στα δεδομένα εκπαίδευσης είτε με τη χρήση τεχνικών μη εποπτευόμενης προσαρμογής τομέων, όπου οι εικόνες μπορούν να «μεταφραστούν» στο στυλ εικόνας της άλλης. Η αύξηση των δεδομένων που εφαρμόζεται σε αυτή τη διατριβή μπορεί να θεωρηθεί ως ένα ελαφρύ μέσο μερικής αντιμετώπισης του προβλήματος προσαρμογής τομέα στα σύνολα δεδομένων για την τεχνητή δημιουργία μικρής μεταβλητότητας, όπως συμβαίνει με τις πραγματικές λήψεις.

Σχετικά με τα κενά στον τομέα είναι τα ζητήματα δικαιοσύνης και απόδοσης σε διαφορετικούς τόνους δέρματος. Εάν το σύνολο δεδομένων παρουσιάζει αυξημένη εμφάνιση κυρίως ανοιχτόχρωμων τύπων δέρματος, είναι πιθανό τα μοντέλα βαθιάς μάθησης να έχουν χαμηλή απόδοση σε πιο σκούρους τόνους δέρματος, ενδεχομένως επιδεινώνοντας τις υπάρχουσες ανισότητες στην υγεία. Αν και το HAM10000 είναι ένα πολύ χρήσιμο σύνολο δεδομένων, δεν καλύπτει όλους τους τύπους δέρματος Fitzpatrick που μπορεί να συναντηθούν σε όλο τον κόσμο. Επομένως, μελλοντικά, αναμένεται ότι η εργασία βαθιάς μάθησης θα επικεντρωθεί περισσότερο στη συλλογή πιο ποικιλόμορφων συνόλων δεδομένων και στη συστηματική αναφορά της ευαισθησίας και της ειδικότητας σε υποομάδες. Αν και αυτού του είδους η ανάλυση απόδοσης για διαφορετικούς τύπους δέρματος δεν εμπίπτει στο πεδίο εφαρμογής αυτής της προσέγγισης υλοποίησης, οι αποφάσεις σχεδιασμού που λαμβάνονται σε όλη αυτή τη διατριβή μπορούν

να ευθυγραμμιστούν με αυτόν τον στόχο ασφαλούς και δίκαιης απόδοσης ως προς διαφορετικές υποομάδες χρηστών μέσω ρητής αναφοράς ευαισθησίας και ειδικότητας και συντηρητικών ζωνών που προσεγγίζουν χαμηλό κίνδυνο.

Συνοψίζοντας την τελευταία τάση που αξίζει να σημειωθεί, υπάρχει μια τάση προς αρχιτεκτονικές που λαμβάνουν υπόψη τους πόρους στη δερματολογία και που στοχεύουν συγκεκριμένα στην ανάπτυξη σε συσκευές με περιορισμούς. Τεχνικές όπως η περικοπή δικτύου, η απόσταξη γνώσης, η αριθμητική μικτής ακρίβειας και οι αρχιτεκτονικές που αναζητούν υποδομές φιλικές προς κινητά (π.χ. MobileNet, EfficientNet-Lite) παρατηρούνται περισσότερο σε άλλους τομείς και, ως εκ τούτου, γίνονται όλο και πιο σχετικές στη δερματολογία. Στο τρέχον σύστημα, το ConvNeXt-Tiny με TensorFlow Lite αντιπροσωπεύει ήδη έναν συμβιβασμό μεταξύ ακρίβειας και αποδοτικότητας, ωστόσο οι βιβλιογραφικές ανασκοπήσεις υποδηλώνουν ότι υπάρχει η δυνατότητα να προωθηθεί η συμπίεση που μειώνει ακόμη πιο δραστικά το μέγεθος των μοντέλων χωρίς καταστροφικές μειώσεις στην απόδοση. Σενάρια που δημιουργήθηκαν για την εξαγωγή float32, δυναμικά κβαντισμένων και float16 παραλλαγών TensorFlow Lite, όλα με στόχο τη βελτιστοποίηση του χρόνου εκτέλεσης και της κατανάλωσης μνήμης και καθώς και τη δυνατότητα χρήσης ενός ενιαίου εκπαιδευμένου κορμού σε πολλαπλές επιλογές ανάπτυξης.

2.8 Συγκριτική ανασκόπηση των συστημάτων αξιολόγησης δερματικών βλαβών

Εκτός από τα ακαδημαϊκά συστήματα που αξιολογούνται σε δημόσια σύνολα δεδομένων, τα τελευταία χρόνια εμφανίζονται όλο και περισσότερες εμπορικές εφαρμογές για κινητά τηλέφωνα, οι οποίες υπόσχονται να αξιολογούν δερματικές βλάβες με βάση φωτογραφίες που λαμβάνονται με το smartphone του χρήστη. Σπάνια δημοσιοποιούνται πληροφορίες σχετικά με την πραγματική εφαρμογή του συστήματος, αλλά συνήθως λειτουργεί με την ίδια λογική: λαμβάνεται μια εικόνα από τον χρήστη, τα δεδομένα υποβάλλονται σε προεπεξεργασία, εισάγεται ένας ταξινομητής και παρέχεται μια βαθμολογία κινδύνου ή μια σύσταση.

Συστηματικές ανασκοπήσεις και πειραματικές μελέτες αναφέρουν σημαντική μεταβλητότητα στην απόδοση αυτών των εφαρμογών, τόσο όσον αφορά την ακρίβεια στη διάκριση του μελανώματος από το μη μελάνωμα όσο και την αξιοπιστία στην απόδοση σε όλες τις ομάδες χρηστών. Σε ορισμένες περιπτώσεις, η αναφερόμενη ευαισθησία σε κακοήθεις βλάβες μπορεί να είναι χαμηλή και να προκαλέσει στον χρήστη ψευδή αίσθηση ασφάλειας, ενώ σε άλλες περιπτώσεις η υπερβολικά αυστηρή ταξινόμηση των βλαβών ως υψηλού κινδύνου μπορεί να οδηγήσει σε άσκοπες επισκέψεις σε γιατρούς και αδικαιολόγητη ανησυχία.

Ένα σημαντικό δίλημμα/πρόβλημα είναι ότι πολλά εμπορικά συστήματα δεν διαθέτουν επαρκή τεκμηρίωση σχετικά με: 1) τα δεδομένα εκπαίδευσης, 2) τα πρωτόκολλα αξιολόγησης και 3) την κλινική επικύρωση. Χωρίς τέτοια τεκμηρίωση, είναι δύσκολο για έναν επαγγελματία υγείας ή μια ρυθμιστική αρχή να αξιολογήσει την πραγματική κλινική χρησιμότητα και τους περιορισμούς της εφαρμογής. Αντίθετα, ερευνητικά έργα όπως αυτό που παρουσιάζεται εδώ περιγράφουν λεπτομερώς τα σύνολα δεδομένων, την αρχιτεκτονική του μοντέλου και τους δείκτες απόδοσης για αναπαραγωγιμότητα και αξιολόγηση.

Υπάρχουν επίσης διαφορές στον τρόπο παρουσίασης των αποτελεσμάτων στον χρήστη. Ορισμένες εφαρμογές αναφέρουν ένα ποσοστό «κινδύνου», με ακρίβεια δύο δεκαδικών ψηφίων, δίνοντας την εντύπωση μεγαλύτερου βαθμού ακρίβειας, ανεξάρτητα από τη βαθμονόμηση του μοντέλου. Άλλα συστήματα χρησιμοποιούν χρωματικούς κώδικες (π.χ. πράσινο, κίτρινο, κόκκινο) για να σηματοδοτήσουν τον βαθμό κινδύνου χωρίς να εξηγούν τι σημαίνει αυτό για τον χρήστη. Η έλλειψη καθορισμένου πλαισίου μπορεί να οδηγήσει είτε σε υπερβολική εμπιστοσύνη στα αποτελέσματα είτε σε πλήρη παραβίασή τους.

Η προσέγγιση σε αυτό το έργο διαφέρει σε δύο σημαντικά σημεία. Πρώτον, το σύστημα έχει σχεδιαστεί ρητά ως ενημερωτικό εργαλείο και όχι ως διαγνωστικό εργαλείο. Τα αποτελέσματα του μοντέλου αντιστοιχίζονται σε ζώνες κινδύνου με ρητές δηλώσεις αποποίησης ευθύνης και προτροπές να ζητηθεί βοήθεια από επαγγελματία υγείας εάν η βλάβη αλλάξει ή προκαλεί ανησυχία. Δεύτερον, το μοντέλο έχει αναπτυχθεί τεχνικά για εκτέλεση σε συσκευή (π.χ. TensorFlow Lite) και δεν απαιτεί την απομακρυσμένη μεταφόρτωση εικόνων σε διακομιστή, μειώνοντας έτσι την πιθανότητα παραβίασης της ιδιωτικότητας.

Τέλος, η συστηματική αναζήτηση χαμηλότερου ορίου και η κατασκευή ζωνών χαμηλού, μεσαίου και υψηλού κινδύνου, όπως περιγράφεται στα επόμενα κεφάλαια, επιτρέπει μια σχετικά διαφανή και καλά τεκμηριωμένη αντιστοίχιση της πιθανότητας κακοήθειας με ποιοτικές ζώνες. Σε αντίθεση με τα ασαφή αποτελέσματα ασφαλείας και μη ασφάλειας, το τρέχον σύστημα έχει σχεδιαστεί για να ενσωματώνει αρχές ασφάλειας, ευθύνης και ρεαλιστικής επικοινωνίας κινδύνου σε χρήστες που ενδεχομένως δεν είναι ειδικοί.

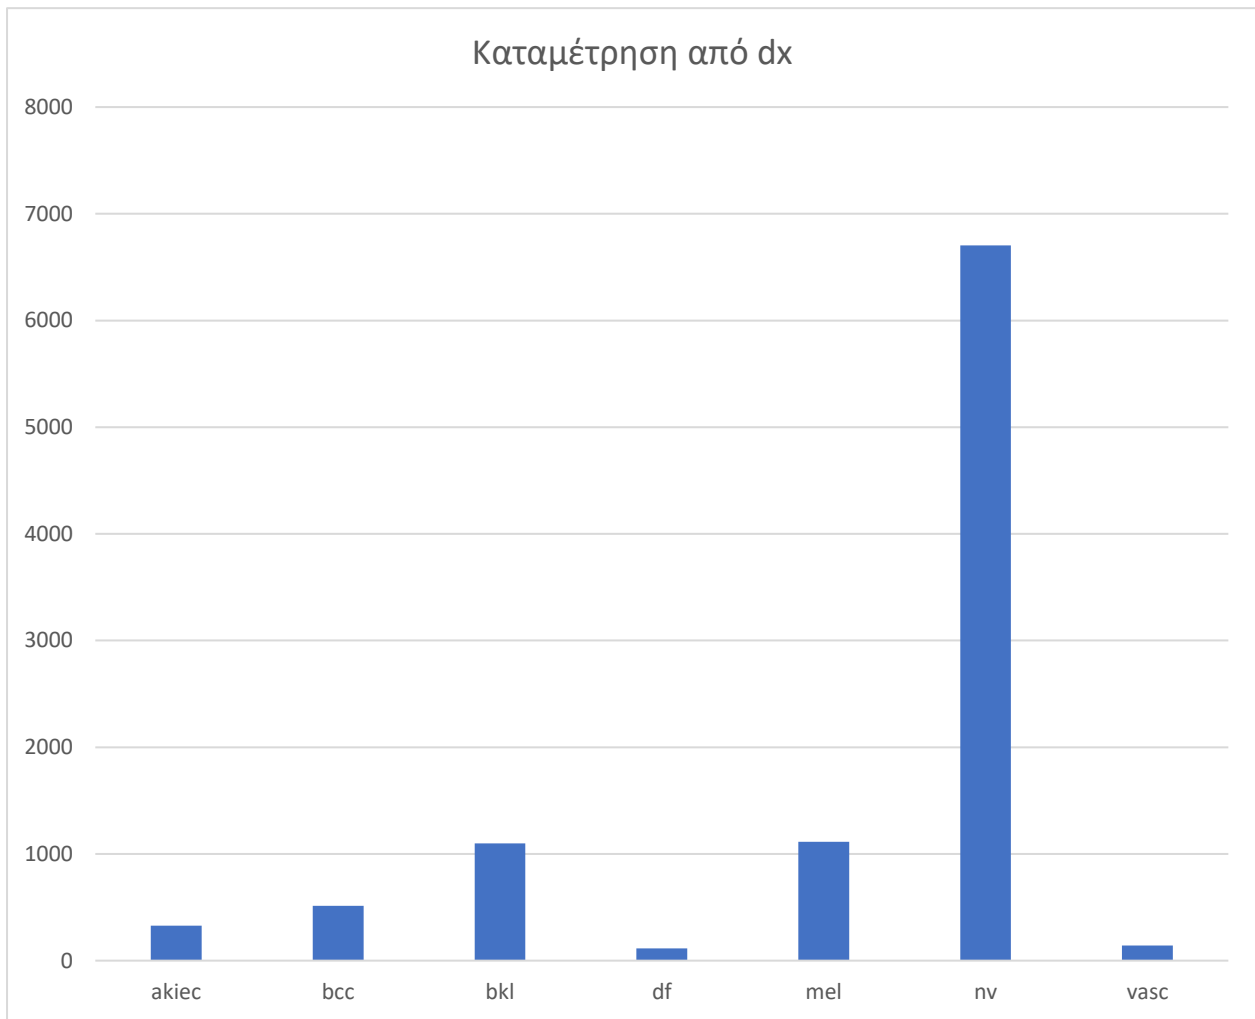
Κεφάλαιο 3ο: Σύνολο δεδομένων και προεπεξεργασία

Αυτό το κεφάλαιο παρουσιάζει το σύνολο δεδομένων που χρησιμοποιήθηκε για την εκπαίδευση και την αξιολόγηση του ταξινομητή δερματικών βλαβών, καθώς και τις διαδικασίες που αφορούν την προετοιμασία των εικόνων και των ετικετών που τροφοδοτούν το μοντέλο. Έμφαση δίνεται στη διαδικασία μετατροπής των ακατέργαστων δεδομένων HAM10000 σε διαφορετικές παρτίδες που τροφοδοτούν το δίκτυο κατά την εκπαίδευση κατά τη διάρκεια της εκπαίδευσης και της επικύρωσης.

3.1 Σύνολο δεδομένων

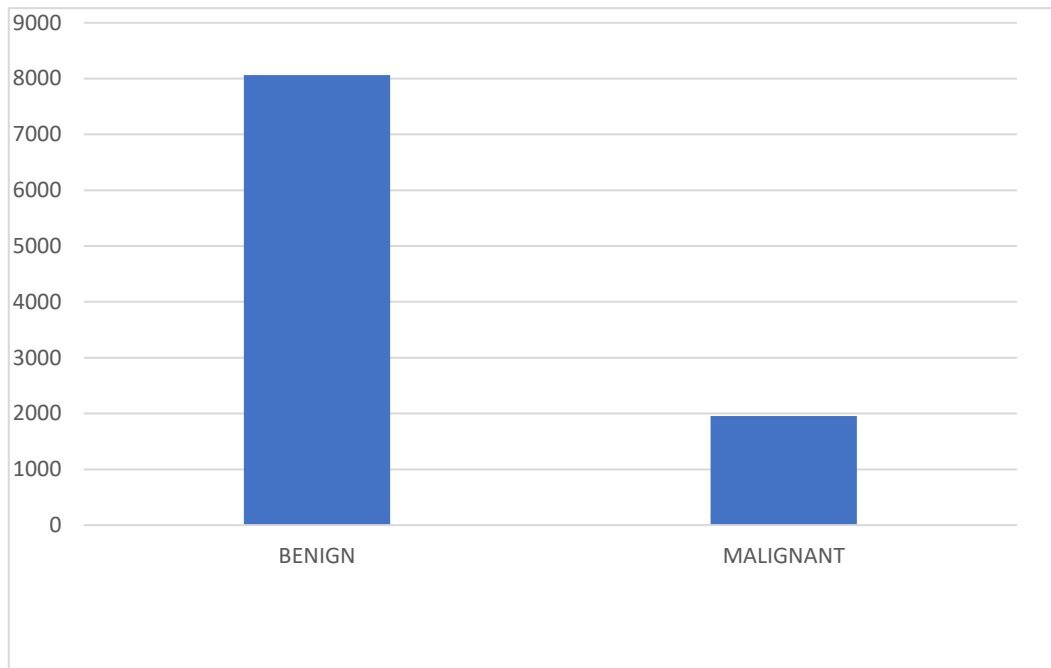
Κάθε πείραμα βασίζεται στο δερματοσκοπικό σύνολο δεδομένων HAM10000 (Human Against Machine με περίπου 10.000 δερματοσκοπικές εικόνες). Το HAM10000 είναι ένα από τα πιο γνωστά δημόσια σύνολα δεδομένων που περιλαμβάνει δερματοσκοπικές εικόνες. Χρησιμοποιείται εκτενώς ως σημείο αναφοράς (benchmark) στην κατηγοριοποίηση δερματικών αλλοιώσεων [10]. Το HAM10000 αποτελείται από δερματοσκοπικές εικόνες χρωματισμένων δερματικών βλαβών, καθώς και από έναν πίνακα μεταδεδομένων σε μορφή CSV. Κάθε σειρά του πίνακα αντιστοιχεί σε μία βλάβη και περιλαμβάνει τον αναγνωριστικό της εικόνας μαζί με μια διαγνωστική ετικέτα και διάφορα άλλα χαρακτηριστικά, όπως η θέση στο σώμα και, σε ορισμένες περιπτώσεις, πληροφορίες σχετικά με τον ασθενή. Οι διαγνωστικές ετικέτες αποτελούνται από διάφορες κλινικά διακριτές οντότητες, όπως μελάνωμα, καλοήθεις αλλοιώσεις τύπου κεράτωσης (benign keratosis-like lesions), βασικοκυτταρικό καρκίνωμα, ακτινικές κερατώσεις και ενδοεπιθηλιακά καρκινώματα, δερματοίωμα και αγγειακές βλάβες. Οι σχετικές εικόνες αποθηκεύονται ως αρχεία JPEG και ονομάζονται σύμφωνα με τον αναγνωριστικό που παρουσιάζεται στον πίνακα μεταδεδομένων.

Η διπλωματική αυτή φιλτράρει πρώτα το σύνολο δεδομένων για να διασφαλίσει ότι διατηρούνται μόνο οι εγγραφές με αντίστοιχο αρχείο εικόνας στο δίσκο. Φορτώνεται ο κατάλληλος πίνακας μεταδεδομένων και για κάθε σειρά υπολογίζεται η αναμενόμενη διαδρομή της εικόνας με βάση έναν προκαθορισμένο κατάλογο εικόνων και τον αντίστοιχο αναγνωριστικό τους. Οι εγγραφές που δεν αναφέρονται ως έχουσες αρχείο εικόνας απορρίπτονται από τον πίνακα. Αν και αυτό μπορεί να φαίνεται ασήμαντο, η απόρριψη εγγραφών για τις οποίες δεν μπορεί να υποστηριχθεί μια εικόνα στην επεξεργασία αποτρέπει σφάλματα κατά την επεξεργασία εικόνων σε μεταγενέστερο στάδιο της διαδικασίας. Επιπλέον, επιβεβαιώνει επίσης ότι κάθε εγγραφή στον πίνακα εργασίας αναφέρεται σε ένα έγκυρο αρχείο JPEG. Οι μόνες εγγραφές που διατηρούνται είναι εκείνες με έγκυρες διαδρομές εικόνας και τις ετικέτες που τους έχουν αποδοθεί. Αυτός ο πίνακας χρησιμεύει ως ο τελικός πίνακας εργασίας για όλη την περαιτέρω επεξεργασία.



Σχήμα 3.1: Κατανομή των διαγνωστικών κατηγοριών στο σύνολο δεδομένων HAM10000, η οποία τονίζει την ανισορροπία μεταξύ καλοήθων και κακοήθων αλλοιώσεων.

Το σύνολο δεδομένων HAM10000 συγκεντρώθηκε κυρίως για την ταξινόμηση βλαβών πολλαπλών κατηγοριών και είναι αντιπροσωπευτικό της κλινικής κατανομής των παθήσεων. Επομένως, πρέπει να σημειωθεί ότι υπάρχει σημαντική ανισορροπία μεταξύ καλοήθων και κακοήθων περιπτώσεων εκ των οποίων οι καλοήθειες βλάβες (ιδιαίτερα οι μελανοκυτταρικοί σπίλοι) αποτελούν τη συντριπτική πλειονότητα των περιπτώσεων. Αυτό μπορεί να διαπιστωθεί στον πίνακα των ακατέργαστων μεταδεδομένων και πρέπει να ληφθεί υπόψη τόσο στην εκχώρηση ετικετών όσο και στην εκπαίδευση. Παρόμοια πρότυπα ανισορροπίας μεταξύ των κλάσεων έχουν παρατηρηθεί σε πολλές ιατρικές βάσεις δεδομένων και είναι γνωστό ότι μπορούν να έχουν αρνητική επίδραση στην εκπαίδευση ταξινομητών, εάν δεν αντιμετωπιστούν σωστά [15].



Σχήμα 3.2: Διαφοροποίηση εικόνων μεταξύ Benign και Malignant.

3.2 Εκχώρηση ετικετών και διαχωρισμός συνόλων εκπαίδευσης και επικύρωσης

Ο στόχος της παρούσας διατριβής είναι η παραγωγή ενός δυαδικού δείκτη κινδύνου μεταξύ καλοήθων και κακοήθων βλαβών. Ως εκ τούτου, οι ετικέτες πολλαπλών κατηγοριών στο HAM10000 συνδυάζονται σε δύο ομάδες. Οι βλάβες που διαγνώστηκαν ως μελάνωμα, βασικοκυτταρικό καρκίνωμα και ακτινική κεράτωση ή ενδοεπιθηλιακό καρκίνωμα ταξινομήθηκαν ως κακοήθειες, ενώ οι βλάβες που ταξινομήθηκαν ως μελανοκυτταρικές σπίλοι, καλοήθειες βλάβες τύπου κεράτωσης, δερματοϊνώματα και αγγειακές βλάβες θεωρήθηκαν καλοήθειες. Αυτή η αντιστοίχιση κωδικοποιείται ως μια καθορισμένη συνάρτηση αντιστοίχισης που λαμβάνει ως είσοδο τη διαγνωστική συμβολοσειρά και επιστρέφει μια δυαδική ετικέτα 0 για καλοήθειες και 1 για κακοήθειες βλάβες.

Μετά τη χαρτογράφηση των δυαδικών ετικετών, το σύνολο δεδομένων χωρίζεται σε ένα σύνολο εκπαίδευσης και ένα σύνολο επικύρωσης. Ο διαχωρισμός γίνεται με στρωματοποιημένο τρόπο, που σημαίνει ότι η σχετική αναλογία καλοήθων και κακοήθων βλαβών διατηρείται περίπου και στα δύο σύνολα. Για τα πειράματα αυτής της διατριβής, πραγματοποιείται διαχωρισμός 80-20: περίπου το 80% των εικόνων θα έχει διατεθεί για το σύνολο εκπαίδευσης και το υπόλοιπο 20% θα κρατηθεί για επικύρωση. Η διαδικασία διαχωρισμού χρησιμοποίησε έναν σταθερό τυχαίο σπόρο για να επιτρέψει την επανάληψη του ίδιου διαχωρισμού κάθε φορά που εκτελείται αυτή η διαδικασία ή για άλλα σενάρια που χρησιμοποιούν το σύνολο επικύρωσης κατά την αξιολόγηση ή την ανάλυση κατωφλίου.


Ένα μοναδικό, σταθερό σύνολο επικύρωσης αντί για τυχαίο διαχωρισμό, ή επαναλαμβανόμενο τυχαίο διαχωρισμό, ή διασταυρούμενη επικύρωση αντικατοπτρίζει τις πρακτικές πραγματικότητες της ανάπτυξης μοντέλων και, στη συνέχεια, της αναζήτησης κατωφλίου. Το σύνολο επικύρωσης εξυπηρετεί δύο σκοπούς: επιτρέπει την παρακολούθηση της απόδοσης κατά τη διάρκεια της διαδικασίας εκπαίδευσης και, μετά την ολοκλήρωση της εκπαίδευσης, επιτρέπει την αξιολόγηση του μοντέλου TensorFlow Lite που εξήχθη, καθώς και την ανάλυση των ορίων απόφασης και των ζωνών κινδύνου. Η χρήση των εικόνων επικύρωσης τόσο για σκοπούς παρακολούθησης όσο και αξιολόγησης εξασφαλίζει μια άμεση σύγκριση της συμπεριφοράς του μοντέλου TensorFlow Lite και του αρχικού μοντέλου Keras, ενώ παράλληλα αποτελεί μια γενική εκτίμηση για αυτόν τον διαχωρισμό.

3.3 Προεπεξεργασία εικόνων

Οι εικόνες στο HAM10000 είναι δερματοσκοπικές φωτογραφίες που έχουν ληφθεί σε ελεγχόμενες συνθήκες, ωστόσο, δεν έχουν όλες ακριβώς την ίδια ανάλυση ή αναλογία διαστάσεων. Επομένως, πρέπει πρώτα να μετατραπούν όλες σε μια συνεπή μορφή πριν χρησιμοποιηθούν ως είσοδος στο δίκτυο. Η διαδικασία προεπεξεργασίας ξεκινά με τη φόρτωση κάθε αρχείου JPEG που είναι αποθηκευμένο στο δίσκο χρησιμοποιώντας μια τυπική βιβλιοθήκη εικόνων και διασφαλίζοντας ότι απεικονίζεται στον χρωματικό χώρο RGB. Εάν μια εικόνα περιέχει κανάλι alpha ή είναι αποθηκευμένη σε διαφορετικό χώρο χρωμάτων, τη μετατρέπουμε ρητά σε RGB.

Το επόμενο βήμα είναι να ληφθεί υπόψη η διακύμανση της αναλογίας διαστάσεων εφαρμόζοντας μια κεντρική περικοπή για να ληφθεί μια τετράγωνη εικόνα. Το μήκος της πλευράς της περικοπής βασίζεται στην μικρότερη πλευρά της αρχικής εικόνας και λαμβάνεται με την κεντράρισή της στο πλαίσιο. Τελικά, αυτή η λειτουργία χρησιμεύει για τη διατήρηση όσο το δυνατόν μεγαλύτερου μέρους της βλάβης και του άμεσου περιβάλλοντός της, ελαχιστοποιώντας ταυτόχρονα την παραμόρφωση που προκαλείται από την μη ομοιόμορφη κλιμάκωση. Η τελική τετράγωνη εικόνα περικοπής κλιμακώνεται στη συνέχεια στην χωρική ανάλυση που απαιτείται από το δίκτυο, η οποία για αυτό το έργο είναι 256 x 256 pixel. Η κλιμάκωση πραγματοποιείται με τη χρήση διγραμμικής παρεμβολής.

Μετά την κλιμάκωση, μετατρέπουμε την εικόνα σε πίνακα κινητής υποδιαστολής, με σταθερή σειρά ύψους, πλάτους και καναλιών χρώματος. Η εξωτερική διαδικασία επεξεργασίας δεν περιλαμβάνει καμία χειροκίνητη κανονικοποίηση, επειδή η αρχιτεκτονική ενσωματώνει ένα backbone ConvNeXt που επιτρέπει την εσωτερική διεξαγωγή της προεπεξεργασίας και καθορίζει τα εύρη των ακατέργαστων τιμών pixel που αναμένει η προεπεξεργασία πριν από την κλιμάκωση, η οποία και πάλι πραγματοποιείται εσωτερικά. Αυτό απλοποιεί τον κώδικα δεδομένων και, κυρίως, παρέχει την ίδια προεπεξεργασία ανεξάρτητα από το αν το μοντέλο εκτελείται ως μοντέλα Keras ή ως διερμηνέας TensorFlow lite. Η ίδια λογική προεπεξεργασίας επαναχρησιμοποιείται στο σενάριο εκπαίδευσης, στο σενάριο αναζήτησης ορίων στο μοντέλο TFlite και σε οποιαδήποτε βοηθητικά σενάρια δοκιμάζουν την αξιολόγηση μεμονωμένων εικόνων.



Σχήμα 3.3: Παράδειγμα από εικόνες που έχουν περάσει από την διαδικασία του augmentation

3.4 Αύξηση δεδομένων και Ανισορροπία κλάσεων

Ενώ οι εικόνες HAM10000 λήφθηκαν με δερματοσκόπια, ως εικόνες υψηλής ποιότητας, η τελική χρήση του συστήματος ήταν σε εικόνες που αναμενόταν να διαφέρουν σημαντικά, οι οποίες είχαν ληφθεί με

smartphone. Επομένως, για να αντιμετωπιστεί αυτό το χάσμα μεταξύ των τομέων (domain gap), εφαρμόστηκε εκτεταμένη τυχαία επαύξηση δεδομένων. Η αύξηση δεδομένων εφαρμόστηκε εν κινήσει, που σημαίνει ότι κάθε φορά που κάθε φορά που το σύνολο δεδομένων ανακτάται και σχηματίζεται μια παρτίδα εκπαίδευσης, υπάρχει η πιθανότητα να εφαρμοστεί μια τυχαία ακολουθία μετασχηματισμών. Επομένως, ενώ το μοντέλο θα εκτίθεται επανειλημμένα στην ίδια υποκείμενη βλάβη, κατά τη διάρκεια κάθε εποχής εκπαίδευσης πολλές διαφορετικές παραλλαγές της ίδιας υποκείμενης βλάβης.

Αυτή η διαδικασία αύξησης υποβάλλει τις εικόνες σε γεωμετρικούς μετασχηματισμούς όπως τυχαία αναστροφή και αντιστροφή των εικόνων οριζόντια και κάθετα και προσθέτει μικρές τυχαίες περιστροφές (σε ακτίνια) γύρω από το κέντρο της εικόνας. Περιλαμβάνει επίσης φωτομετρικές τροποποιήσεις: η φωτεινότητα και η αντίθεση διαταράσσονται εντός καθορισμένων ορίων, ενώ περιστασιακά τροποποιείται ο κορεσμός του χρώματος. Περιλαμβάνονται επιπλέον μετασχηματισμοί για την καλύτερη αποτύπωση των ατελειών που είναι πιθανό να παρατηρηθούν σε πραγματικές φωτογραφίες. Αυτοί οι πρόσθετοι μετασχηματισμοί προσομοιώνουν θολές και συμπιεσμένες εικόνες. Τέλος, ορισμένες εικόνες εκπαίδευσης φέρουν συνθετικές σκούρες καμπύλες που μοιάζουν με τρίχες που διασχίζουν τη βλάβη. Αυτές οι συνθετικές τρίχες δεν ακολουθούν καθορισμένες διαδρομές ή πάχη, αλλά εμφανίζουν άλλα μεταβλητά χαρακτηριστικά. Είναι φωτεινές και μπορούν να είναι σχεδόν διαφανείς. Αυτές οι συνθετικές γραμμές έχουν ως στόχο να αναπαράγουν μία από τις πιο κοινές πηγές απόφραξης, είτε σε δερματοσκοπικές εικόνες είτε σε μη δερματοσκοπικές εικόνες. Ο στόχος της έκθεσης του μοντέλου σε αυτά τα τεχνητά στοιχεία κατά τη διάρκεια της εκπαίδευσης είναι να το καταστήσει λιγότερο ευαίσθητο σε παρόμοιες διαταραχές κατά τη διάρκεια της δοκιμής.

Λόγω του προβλήματος της ανισορροπίας των κατηγοριών, τα δεδομένα προετοιμάζονται με τέτοιο τρόπο ώστε να χρησιμοποιείται ένας συνδυασμός υπερδειγματοληψίας και σταθμισμένης απώλειας κατηγοριών. Το αρχικό σύνολο δεδομένων έχει πολύ μεγαλύτερο αριθμό καλοήθων βλαβών σε σύγκριση με τις κακοήθεις βλάβες. Εάν οι παρτίδες δειγματοληπτούνταν σε πραγματική αναλογία με αυτή την κατανομή, το μοντέλο θα έβλεπε σχετικά λίγα κακοήθη παραδείγματα, ενώ θα επέτυχε υψηλή ακρίβεια απλώς στοχεύοντας στην πλειοψηφούσα κατηγορία. Ταυτόχρονα, η δυαδική διασταυρούμενη εντροπία απώλειας σταθμίζεται ανά κατηγορία, έτσι ώστε τα σφάλματα στις κακοήθεις βλάβες να συμβάλλουν περισσότερο στη συνολική απώλεια από τα σφάλματα στις καλοήθεις βλάβες. Αυτές οι προσπάθειες αλληλοϋποστηρίζονται: η υπερδειγματοληψία αυξάνει τη συνολική μεταβλητότητα των κακοήθων εικόνων που παρατηρούνται κατά τη διάρκεια της εκπαίδευσης, ενώ η στάθμιση κατηγοριών αντικατοπτρίζει τη σχετική σημασία τους στον στόχο της συνολικής βελτιστοποίησης του μοντέλου.

Η υπερδειγματοληψία χρησιμοποιείται για την εξισορρόπηση της συχνότητας εμφάνισης των κακοήθων δειγμάτων κατά τη δειγματοληψία παρτίδων, ενώ η στάθμιση κλάσεων επηρεάζει αποκλειστικά τη συνάρτηση απώλειας, ενισχύοντας τη συνεισφορά των κακοήθων σφαλμάτων στη διαδικασία βελτιστοποίησης. Οι δύο τεχνικές λειτουργούν συμπληρωματικά και δεν είναι πλεοναστικές. Το συνδυασμένο αποτέλεσμα των σταδίων προεπεξεργασίας, επαύξησης και εξισορρόπησης είναι ο καθορισμός της κατανομής των εικόνων και της κατανομής των ετικετών από τις οποίες μαθαίνει το μοντέλο. Το μοντέλο δεν βλέπει απευθείας τις ακατέργαστες εικόνες HAM10000, αλλά επαυξημένες, κεντροθετημένες και αναδιαστασιολογημένες εικόνες που έχουν δειγματοληφθεί από μια προσαρμοσμένη κατανομή δειγματοληψίας.

3.5 Στρατηγικές εμπλουτισμού και γενίκευσης των συνόλων δεδομένων

Η απόδοση του ταξινομητή σχετικά με τις καλοήθεις και κακοήθεις δερματικές αλλοιώσεις εξαρτάται σε μεγάλο βαθμό από το επίπεδο ποικιλομορφίας και αντιπροσωπευτικότητας του συνόλου δεδομένων

εκπαίδευσης. Αν και το HAM10000 είναι ένα ευρέως χρησιμοποιούμενο και καλά χαρακτηρισμένο δερματοσκοπικό σύνολο δεδομένων, εξακολουθεί να βασίζεται σε ένα συγκεκριμένο κλινικό και γεωγραφικό πλαίσιο και έχει μια ατελή αναπαράσταση ορισμένων τύπων δέρματος. Ως εκ τούτου, υπάρχει μια ευκαιρία εμπλουτισμού για την υποστήριξη του αρχικού συνόλου δεδομένων HAM10000 με πολλές άλλες δημόσια διαθέσιμες πηγές που μπορούν να βρεθούν μέσω των προκλήσεων ISIC. Προκειμένου να συγχωνευθούν σωστά πολλαπλά σύνολα δεδομένων, απαιτείται προσεκτική εναρμόνιση των ετικετών (που σχετίζονται με τις διαγνωστικές κατηγορίες) και μηχανισμοί για την ανίχνευση και τον καθαρισμό πιθανών σφαλμάτων σχολιασμού. Επιπλέον, πρέπει να ληφθούν υπόψη πιθανές μεταβολές του τομέα κατά τη χρήση αυτών των διαφορετικών πηγών, όπως οι επιδράσεις της ανάλυσης της εικόνας, του χρώματος, του φωτισμού ή των συσκευών απεικόνισης. Εάν δεν ληφθούν υπόψη τέτοιες μεταβολές του τομέα, το μοντέλο μπορεί να αναπτύξει «ψευδείς» συσχετίσεις που δεν γενικεύονται πέρα από τον συνδυασμό των συνόλων δεδομένων που χρησιμοποιούνται στην εκπαίδευση του μοντέλου.

Μια εναλλακτική αλλά πολύ ενδιαφέρουσα κατεύθυνση είναι η διερεύνηση της χρήσης τεχνικών προσαρμογής τομέα (DA) για τη γεφύρωση του χάσματος μεταξύ των κλινικών δεδομένων δερματοσκόπησης και των φωτογραφιών «καταναλωτικού επιπέδου» από smartphone. Η προσέγγιση DA έχει γενικά διάφορες επιλογές, όπως η χαρτογράφηση εικόνων από διαφορετικούς τομείς σε έναν ενιαίο χώρο λανθάνων χαρακτηριστικών, η χρήση ενός συνδυασμού αντιθετικών απωλειών για την προώθηση ενός αμετάβλητου τομέα και/ή η χρήση συνθετικών δεδομένων που μιμούνται τις πραγματικές συνθήκες λήψης φωτογραφιών. Η σταθερότητα του μοντέλου είναι ο τελικός στόχος κατά τη μετάβαση από τη εργαστηριακή διάταξη της δερματοσκόπησης στο μεταβλητό και ακανόνιστο καθημερινό περιβάλλον.

Με βάση τα θεμέλια αυτής της εργασίας, ο εμπλουτισμός του συνόλου δεδομένων χρησιμοποιεί κυρίως την αύξηση δεδομένων και τη διαχείριση ανισορροπίας κλάσεων. Όλες οι αυξήσεις πραγματοποιήθηκαν κατά τη διάρκεια της υλοποίησης χρησιμοποιώντας ένα σενάριο εκπαίδευσης που θα δημιουργούσε έναν ατελείωτο αριθμό εκδόσεων κάθε δερματοσκοπικής εικόνας εφαρμόζοντας τυχαίες μετασχηματισμούς, όπως τυχαία περικοπή, περιστροφή, ζουμ, ρυθμίσεις φωτεινότητας και αντίθεσης, θόλωση Gaussian (Gaussian blur), τεχνητά στοιχεία συμπίεσης JPEG και, σε ορισμένες περιπτώσεις, προσθέτοντας συνθετικά συνθετικά επικαλύμματα τριχών (hair overlays) που δημιουργήθηκαν χρησιμοποιώντας το PIL ImageDraw module. Αυτές οι μετασχηματισμοί δημιουργούν συνθετικά τεχνητά στοιχεία παρόμοια με αυτά που βλέπουμε στις ζωντανές εικόνες για κίνηση, σκιές, συμπίεση κάμερας και μαλλιά που καλύπτουν.

Η διαδικασία εκπαίδευσης εστιάζει επίσης σε μεγάλο βαθμό στην ανισορροπία κλάσεων ως βασικό στοιχείο της στρατηγικής εμπλουτισμού του συνόλου δεδομένων. Ακόμη και μετά τις αυξήσεις, οι κακοήθεις βλάβες εξακολουθούν να είναι σημαντικά λιγότερες από τις καλοήθεις βλάβες. Αντί να κάνουμε απλώς υπερδειγματοληψία των κακοήθων περιπτώσεων, χρησιμοποιούμε έναν συνδυασμό στρωματοποιημένης διαίρεσης και στάθμισης κατηγοριών κατά τη διάρκεια της εκπαίδευσης: ένα θετικό βάρος κατηγορίας που είναι ανάλογο με την αναλογία αρνητικών προς θετικά μεταβιβάζεται στη μέθοδο fit() του Keras για να κάνει τη συνάρτηση απώλειας πιο ευαίσθητη σε ένα κακοήθες παράδειγμα, ενθαρρύνοντας τον βελτιστοποιητή να επικεντρωθεί στις κακοήθεις βλάβες χωρίς να εμφανίζει τις ίδιες εικόνες επαναληπτικά, κάτι που θα μπορούσε να οδηγήσει σε υπερπροσαρμογή.

Από μια υψηλότερη προοπτική, η ροή δεδομένων μας έχει δημιουργηθεί για μελλοντική ανάπτυξη. Ο σχεδιασμός επιτρέπει την εύκολη διαμόρφωση που θα βρείτε τις εικόνες HAM10000 και το αρχείο CSV μεταδεδομένων. Όταν δημιουργήσαμε το DataFrame που περιείχε το Image ID και το Label Bin,

χρησιμοποιήσαμε βοηθητικές λειτουργίες για να απλοποιήσουμε αυτή τη διαδικασία. Η προσθήκη νέων πηγών δεδομένων στο μέλλον είτε πρόκειται για δημόσια διαθέσιμα σύνολα δεδομένων είτε για ιδιόκτητες συλλογές από κλινικούς συνεργάτες είναι μια διαδικασία που μπορεί να υλοποιηθεί με ελάχιστες αλλαγές στον υπάρχον αγωγό και θα απαιτήσει πολύ λίγες αλλαγές στον κώδικα μας. Νέες πληροφορίες, όπως η ηλικία του ασθενούς, το φύλο ή η θέση της βλάβης, μπορούν επίσης να συμπεριληφθούν με πολύ παρόμοιο τρόπο, ώστε να είναι δυνατή η πολυτροπική μάθηση χωρίς να χρειάζεται να ξαναγραφεί ολόκληρος ο κώδικας εκπαίδευσης και αξιολόγησης.

Ένα άλλο σημαντικό βήμα προς την εκτίμηση της ικανότητας γενίκευσης είναι η αξιολόγηση σε ένα εξωτερικό σύνολο δοκιμών που δεν χρησιμοποιήθηκε ποτέ κατά τη διάρκεια της εκπαίδευσης ή της ρύθμισης των υπερπαραμέτρων. Ενώ το επίκεντρο αυτής της εργασίας είναι το σύνολο δεδομένων HAM10000, ο αρθρωτός σχεδιασμός του σωλήνα δεδομένων και του σεναρίου εκπαίδευσης επιτρέπει την προσθήκη άλλων πρόσθετων πηγών δεδομένων στο μέλλον και τη συστηματική σύγκρισή τους μεταξύ τους, προκειμένου να αξιολογηθεί περαιτέρω ο βαθμός γενίκευσης του μοντέλου σε διαφορετικούς πληθυσμούς και συνθήκες απόκτησης.

3.6 Κλινικά μεταδεδομένα, ποιότητα ετικετών και μεροληψίες σε σύνολα δεδομένων

Τα σύνολα δεδομένων του πραγματικού κόσμου, συμπεριλαμβανομένου του HAM10000, περιέχουν κάποιο επίπεδο θορύβου και μεροληψίας που σχετίζεται με τη δημιουργία των ετικετών. Το HAM10000 περιέχει ετικέτες από διαφορετικές πηγές (ιστοπαθολογία, επισκέψεις παρακολούθησης, συναίνεση εμπειρογνομόνων), με την ιστοπαθολογία να θεωρείται το χρυσό πρότυπο για τις ετικέτες. Από την άλλη πλευρά, οι ετικέτες που δημιουργούνται από οπτική επιθεώρηση, επισκέψεις παρακολούθησης κ.λπ. είναι πιο αβέβαιες. Η στήλη ετικετών (dx) σε αυτόν τον αγωγό αντιμετωπίζει όλες τις ετικέτες ομοίωμα κατά την εκπαίδευση του μοντέλου. Δεν υπάρχει συγκεκριμένη διαφοροποίηση μεταξύ διαφορετικών βαθμών διαγνωστικής βεβαιότητας κατά την εκπαίδευση. Επομένως, ενώ αυτό απλοποιεί την εκπαίδευση του μοντέλου, σημαίνει επίσης ότι σπάνιες περιπτώσεις λανθασμένης επισήμανσης μπορούν να επηρεάσουν το όριο απόφασης που έχει μάθει το μοντέλο.

Η κατανομή των διαγνωστικών κατηγοριών είναι επίσης σημαντική κατά την αξιολόγηση της ποιότητας των ετικετών. Αν και αρκετές καλοήθειες κατηγορίες, όπως οι κοινές σπίλοι, έχουν σημαντική εκπροσώπηση, πολλές έχουν σχετικά μικρό αριθμό. Για παράδειγμα, αν και οι καλοήθειες και κακοήθειες βλάβες ποικίλλουν σε μεγάλο βαθμό μεταξύ των ατόμων, όλες αντιπροσωπεύουν το ίδιο επίπεδο απώλειας σε σχέση με το μοντέλο. Ωστόσο, όσον αφορά την κλινική συνάφεια, μια λανθασμένη διάγνωση μιας προφανής βλάβης θα μπορούσε να έχει διαφορετικούς κινδύνους από μια λανθασμένη διάγνωση μιας πολύ λεπτή βλάβης. Περαιτέρω έρευνα θα μπορούσε να καθορίσει εάν η στάθμιση των δειγμάτων με βάση την πηγή των ετικετών ή τη δυσκολία του ευρήματος θα δημιουργούσε ένα καλύτερο μοντέλο. Ενώ οι ετικέτες είναι βασικές για την ταξινόμηση των εικόνων, λαμβάνονται υπόψη πολλοί άλλοι παράγοντες. Για παράδειγμα, η ηλικία, το φύλο και η θέση μιας βλάβης στο σώμα παρέχουν πληροφορίες για τον τρόπο ταξινόμησης αυτής της βλάβης, εκτός από το ότι αποτελούν την κύρια μέθοδο ταξινόμησης. Επομένως, χρησιμοποιώντας την ηλικία ως παράδειγμα, η γνώση της ηλικίας ενός ασθενούς επιτρέπει σε ένα μοντέλο να προσδιορίσει τη βασική πιθανότητα μελανώματος με βάση την χρονολογική ηλικία του και τη γενική κατανομή των τύπων μελανώματος σε διαφορετικές ανατομικές θέσεις. Χρησιμοποιώντας επί του παρόντος μόνο τα εικονοστοιχεία μιας εικόνας (που αντιπροσωπεύουν τη βλάβη) και μια δυαδική ετικέτα (ναι/όχι για μελάνωμα), μια παραλλαγή του τρέχοντος συστήματος θα περιλαμβάνει μεταδεδομένα εκτός από τα δεδομένα εικονοστοιχείων για τη βελτίωση της ακρίβειας της ταξινόμησης. Σε αυτό το σενάριο, τα μεταδεδομένα μπορούν να συνδυαστούν είτε μέσω συνένωσης με τον διανυσματικό χαρακτηριστικό της εικόνας που λαμβάνεται

μετά τη διέλευση από το ConvNeXt-Tiny, είτε μέσω επεξεργασίας από ένα βοηθητικό συνδεδεμένο δίκτυο και συνδυασμού με την αναπαράσταση βάσει εικόνας για να σχηματιστεί ένα πολυτροπικό μοντέλο. Τα πολυτροπικά μοντέλα είναι πιθανό να αποφέρουν βελτιωμένη βαθμονόμηση και πιο εκλεπτυσμένα όρια λήψης αποφάσεων. Ωστόσο, η πρόσθετη ενσωμάτωση μεταδεδομένων προσθέτει πολυπλοκότητα στην εφαρμογή του μοντέλου και αυστηρότερες απαιτήσεις για την απόκτηση δεδομένων για τη λύση CAD.

Οι ρυθμίσεις των ασθενών και της απόκτησης προκαλούν συστηματικές διαφορές που δημιουργούν μεροληψία. Μια ομάδα ασθενών που δεν περιλαμβάνει διάφορους τύπους δέρματος οδηγεί σε ένα μοντέλο που αναπτύσσει μια «συντόμηση» για την ταξινόμηση που βασίζεται στο χρώμα του δέρματος ως φόντο και όχι στα μορφολογικά χαρακτηριστικά της βλάβης. Οι ομάδες ασθενών που απεικονίζονται σε μία μόνο κλινική μπορεί να έχουν μια χρωματική ισορροπία που διαφέρει ελαφρώς από εκείνη του ίδιου τύπου δέρματος σε άλλες κλινικές, οδηγώντας σε ένα μοντέλο που χρησιμοποιεί αυτή την «εγγύτητα» ως κριτήριο διάγνωσης. Χρησιμοποιώντας την ενίσχυση του χρώματος και της φωτεινότητας στην εκπαιδευτική διαδικασία, σκοπεύουμε να μετριάσουμε ή να αποτρέψουμε το μοντέλο από το να βασίζεται στην ταξινόμηση σε «συντομεύσεις» που σχετίζονται με διακυμάνσεις στο χρώμα ή τη φωτεινότητα του δέρματος που δεν προκαλούνται από υποκείμενη παθολογία. Επομένως, αν και η ενίσχυση του χρώματος και της φωτεινότητας είναι χρήσιμη, ο καλύτερος τρόπος για να μετριάσει ή να μετριάσει η μεροληψία είναι η ανάπτυξη ενός πιο ποικιλόμορφου και αντιπροσωπευτικού πληθυσμού ασθενών από τον οποίο θα συλλέγονται δεδομένα.

Συμπερασματικά, η συλλογή ασθενών του HAM10000 παρέχει ένα εξαιρετικό σύνολο δεδομένων που μπορεί να χρησιμοποιηθεί για την εκπαίδευση και την αξιολόγηση του μοντέλου. Ωστόσο, κατά την αξιολόγηση των αποτελεσμάτων του μοντέλου και την επέκταση του μοντέλου σε άλλες ομάδες ασθενών στο μέλλον, είναι απαραίτητη η πλήρης αξιολόγηση των δεδομένων εντός μιας συγκεκριμένης ποιότητας ετικέτας HAM10000, των πληροφοριών μεταδεδομένων (π.χ. λήψη εικόνων, τοποθεσίες και άλλα μεταδεδομένα) και οποιουδήποτε πιθανού μεροληψίας. Η δυνατότητα συμπερίληψης άλλων στηλών μεταδεδομένων από το CSV μεταδεδομένων και η δυνατότητα εύκολης προσθήκης νέων συνόλων δεδομένων στην ροή εργασίας αποτελεί ένα σημαντικό βήμα στην ανάπτυξη μιας αμερόληπτης και κλινικά εφαρμόσιμης λύσης CAD.

3.7 Λεπτομέρειες υλοποίησης του αγωγού δεδομένων

Ο αγωγός δεδομένων λειτουργεί με αυτόν τον τρόπο για αυτό το έργο, γεφυρώνοντας το χάσμα μεταξύ των ακατέργαστων αρχείων HAM10000 και των δομημένων τανυστών και παρτίδων δεδομένων (batches), όπως απαιτούνται από το πλαίσιο TensorFlow/Keras. Ο αγωγός δεδομένων μπορεί να περιγραφεί εννοιολογικά ως μια διαδικασία σταδιακής μετατροπής, η οποία ξεκινά από έναν κατάλογο εικόνων και ένα αρχείο CSV μεταδεδομένων και καταλήγει στη δημιουργία δύο αντικειμένων `tf.data.Dataset` για εκπαίδευση και επικύρωση.

Ο αγωγός δεδομένων ξεκινά με τη φόρτωση του CSV μεταδεδομένων ως `Pandas DataFrame` και διατηρεί μόνο τις απαραίτητες στήλες που παρουσιάζουν ενδιαφέρον - `Image ID` (μοναδικό) και `Original Diagnosis Code` όπως ορίζεται. Δεύτερον, αντιστοιχίζει κάθε κωδικό διάγνωσης με την αντίστοιχη δυαδική ετικέτα χρησιμοποιώντας καθορισμένα σύνολα κακοήθων (`{“akiec”, “bcc”, “mel”}`) και καλοήθων (`{“bkl”, “nv”, “vasc”, “df”}`) βλαβών. Δεδομένου ότι οποιοσδήποτε κωδικός διάγνωσης εκτός των προηγουμένως καθορισμένων συνόλων προκαλεί αμφισημία, όλες αυτές οι σειρές παραλείπονται από την περαιτέρω επεξεργασία. Στη συνέχεια, ο αγωγός ελέγχει κάθε μοναδικό αναγνωριστικό εικόνας για την ύπαρξη ενός αρχείου εικόνας JPEG στο δίσκο, απορρίπτοντας όλες τις

σειρές που δεν έχουν αντίστοιχο αρχείο JPEG. Αυτό μας αφήνει με ένα καθαρό DataFrame που περιέχει μόνο έγκυρα ζεύγη (`image_id,label`).

Για να διαχωρίσει το δημιουργημένο DataFrame σε δύο ξεχωριστά υποσύνολα για Εκπαίδευση και Επικύρωση, το σενάριο θα πραγματοποιήσει μια στρωματοποιημένη διαίρεση του DataFrame με βάση την δυαδική ετικέτα. Ο σταθερός τυχαίος σπόρος επιτρέπει μια στρωματοποιημένη διαίρεση ανακάτεμα, προκειμένου να χωριστεί κατάλληλα ολόκληρο το σύνολο δεδομένων σε μια διαίρεση 80/20 σε σχέση με τα σύνολα εκπαίδευσης/επικύρωσης, διατηρώντας παράλληλα τις αναλογίες των κακοήθων προς τις καλοήθειες βλάβες σε κάθε σύνολο δεδομένων. Μια αξιόπιστη αξιολόγηση της απόδοσης του μοντέλου χρειάζεται σύνολο επικύρωσης ώστε να περιλαμβάνει επαρκή αριθμό κακοήθων παραδειγμάτων. Εάν το σύνολο δεδομένων επικύρωσης είναι εξαιρετικά ανισορροπημένο σε σχέση με τον αριθμό των κακοήθων βλαβών σε σύγκριση με τις καλοήθειες βλάβες, η αξιολόγηση θα είναι μεροληπτική και οι μετρήσεις ακρίβειας και ευαισθησίας πιθανότατα θα εμφανίζουν τεχνητά υψηλές τιμές, επειδή το μοντέλο θα υπολογίζει την ακρίβεια μόνο με βάση την αναλογία των καλοήθων έναντι των κακοήθων βλαβών.

Η ίδια μέθοδος στρωματοποιημένης ανακατάταξης θα χρησιμοποιηθεί για την αξιολόγηση των μοντέλων TFLite μέσω του TensorFlow Lite Threshold Search Script. Επομένως, το υποσύνολο επικύρωσης για κάθε ένα από τα μοντέλα που υποβάλλονται σε επεξεργασία από την αναζήτηση κατωφλίου TensorFlow Lite θα έχει επίσης τα ίδια χαρακτηριστικά απόδοσης.

Αν και το σύνολο δεδομένων εκπαίδευσης είναι πλέον πιο ισορροπημένο, εξακολουθεί να υπάρχει ανισορροπία στον αριθμό των κακοήθων βλαβών σε σύγκριση με τον αριθμό των καλοήθων βλαβών. Προκειμένου να συμβάλει στην άμβλυνση αυτού του προβλήματος, το έργο εφαρμόζει μια μορφή υπερδειγματοληψίας, αντιγράφοντας τις σειρές κάθε εικόνας που σχετίζεται με κακοήθειες βλάβες, έως ότου ο συνολικός αριθμός σειρών για κακοήθειες βλάβες είναι περίπου ίσος με τον συνολικό αριθμό σειρών για καλοήθειες βλάβες. Το αποτέλεσμα αυτής της υπερδειγματοληψίας θα παρέχει ένα πολύ πιο ισορροπημένο σύνολο δεδομένων για εκπαίδευση. Επιπλέον, κατά τη διάρκεια της διαδικασίας εκπαίδευσης, το μοντέλο θα υπολογίσει επίσης ένα λεξικό `class_weight` για να παρέχει επιπλέον βάρος για κάθε συγκεκριμένη κατηγορία κακοήθων βλαβών σε σχέση με το βάρος που σχετίζεται με την κατηγορία των καλοήθων βλαβών στη συνάρτηση απώλειας. Τελικά, αυτό θα έχει ως αποτέλεσμα να δοθεί επιπλέον έμφαση στην βελτιστοποίηση των βαρών του μοντέλου που σχετίζονται με την πρόβλεψη κακοήθων βλαβών μέσω της σύγκλισης του βελτιστοποιητή.

Αφού ολοκληρωθεί η διαίρεση και η πιθανή υπερδειγματοληψία των συνόλων δεδομένων εκπαίδευσης και επικύρωσης, το επόμενο βήμα είναι η δημιουργία των αγωγών `tf.data`. Η βοηθητική λειτουργία γεννήτριας αυτού του έργου θα παράγει ζεύγη στοιχείων (`image_path, label`) από το σύνολο δεδομένων εκπαίδευσης για να εκθέσει τα δεδομένα ως τανυστές μέσω ενός αγωγού δεδομένων βασισμένο στο TFLite, ο οποίος επιτρέπει τη ροή δεδομένων σε πραγματικό χρόνο και την εφαρμογή αλλαγών και μετασχηματισμών κατά την διάρκεια της εκπαίδευσης. Η συνάρτηση Python θα εκτελέσει τη φόρτωση της εικόνας, την προεπεξεργασία της εικόνας, όπως το κεντροθετικό κροπάρισμα σε τετράγωνο σχήμα, και την επαύξηση της εικόνας για να δημιουργήσει μια πλήρη επαυξημένη εικόνα, εάν βρίσκεται σε λειτουργία εκπαίδευσης. Το αντικείμενο εικόνας που προκύπτει από την επαύξηση θα μετατραπεί σε αντικείμενο `float32 NumPy` και η αντίστοιχη ετικέτα θα επιστραφεί ως μια έκδοση της ετικέτας `float32 TensorFlow friendly`.

Το προκύπτον `tf.data.Dataset` που παράγεται μέσω των μεθόδων που περιγράφονται παραπάνω θα δημιουργηθεί με όλα τα κοινά χαρακτηριστικά που σχετίζονται με τη βελτιστοποιημένη απόδοση, όπως επαρκές μέγεθος `buffer` για την ανακατάταξη των δεδομένων εκπαίδευσης συνέπεια όσον αφορά τη

διαίρεση του συνόλου δεδομένων εκπαίδευσης σε παρτίδες (batch_size) και δυνατότητα των χρηστών να προ-ανακτούν δεδομένα του αγωγού εισόδου, ώστε να είναι διαθέσιμα παράλληλα με την εκτέλεση του μοντέλου (δηλ. αποφυγή δημιουργίας πιθανής συμφόρησης χρησιμοποιώντας tf.py_function για την κλήση Python για τη φόρτωση εικόνων). Ένας σωστά σχεδιασμένος αγωγός προεπεξεργασίας δεδομένων θα διευκολύνει το αναμενόμενο σενάριο της διατήρησης της λειτουργίας της GPU ή της CPU του TensorFlow, αντί της άσκοπης αναμονής για το επόμενο σημείο δεδομένων.

Μια βασική απόφαση που ελήφθη κατά το σχεδιασμό αυτού του έργου ήταν ότι τόσο ο αγωγός προεπεξεργασίας δεδομένων για τη διαδικασία εκπαίδευσης Keras όσο και ο αγωγός προεπεξεργασίας δεδομένων που είναι απαραίτητος για την επακόλουθη αξιολόγηση των μοντέλων χρησιμοποιώντας τις αξιολογήσεις TensorFlow Lite (αναζητήσεις κατωφλίου) θα δημιουργηθούν με τον ίδιο ακριβώς αγωγό εκτέλεσης. Σε όλες τις πτυχές της ανάπτυξης, όπως σημειώθηκε προηγουμένως, το υποσύνολο επικύρωσης που θα χρησιμοποιηθεί για κάθε μία από τις αξιολογήσεις TensorFlow Lite θα υποβληθεί στις ίδιες διαδικασίες προεπεξεργασίας και δεν θα παρεμβληθούν διαδικασίες επαύξησης. Ο στόχος της διατήρησης του ίδιου αγωγού προεπεξεργασίας δεδομένων τόσο για την εκπαίδευση Keras όσο και για την επακόλουθη αξιολόγηση των μοντέλων TFLite είναι να παρέχεται συνέχεια μεταξύ της διαδικασίας αξιολόγησης και της διαδικασίας συμπερασμού. Ένας καλά δομημένος αγωγός προεπεξεργασίας θα πρέπει να παρέχει μια μέθοδο για την απλοποίηση, τον καθαρισμό και τη βελτιστοποίηση της διαδικασίας ανάπτυξης του μοντέλου TFLite.

3.8 Συμπεράσματα

Σε αυτό το κεφάλαιο, παρέχουμε μια λεπτομερή εξήγηση για τον τρόπο με τον οποίο επεξεργαστήκαμε τα ακατέργαστα δεδομένα από το αρχείο δερματοσκοπικών εικόνων HAM10000 σε μια δομημένη μορφή που μας επέτρεψε να δημιουργήσουμε και να αξιολογήσουμε ένα μοντέλο δυαδικής ταξινόμησης για τις κατηγορίες καλοήθων και κακοήθων όγκων. Το αρχικό βήμα της διαδικασίας εισαγωγής του συνόλου δεδομένων είναι το φιλτράρισμα όλων των εγγραφών που δεν έχουν έγκυρα μεταδεδομένα και η αντιστοίχιση των ετικετών διάγνωσης πολλαπλών κατηγοριών με μια δυαδική ετικέτα, καθώς και η διασφάλιση ότι κάθε εγγραφή που παραμένει έχει μια εικόνα που αντιστοιχεί σε αυτήν την εγγραφή στο δίσκο. Αυτό το αρχικό βήμα του φιλτραρίσματος των μη έγκυρων εγγραφών διασφαλίζει ότι δεν υπάρχει κανένας τρόπος να εκπαιδευτεί ή να δοκιμαστεί κατά λάθος το μοντέλο χρησιμοποιώντας μη έγκυρα ή ελλιπή δεδομένα, και αυτό αποτελεί μια εξαιρετική βάση για την ισορροπία των διαδικασιών που περιγράφονται σε αυτό το κεφάλαιο.

Στη συνέχεια, συζητήσαμε πώς χωρίσαμε το επικυρωμένο σύνολο δεδομένων σε δύο νέα υποσύνολα για σκοπούς εκπαίδευσης και επικύρωσης. Για να το επιτύχουμε αυτό, χρησιμοποιήσαμε τη μέθοδο στρωματοποιημένης δειγματοληψίας για τον διαχωρισμό των συνόλων δεδομένων, η οποία διατηρεί τις σχετικές αναλογίες τόσο των καλοήθων όσο και των κακοήθων τύπων βλαβών. Αυτό είναι εξαιρετικά σημαντικό για τη δημιουργία αξιόπιστων αξιολογήσεων απόδοσης στο τελικό μοντέλο. Εάν το σύνολο επικύρωσης περιέχει λιγότερα παραδείγματα κακοήθων βλαβών από το σύνολο εκπαίδευσης, οι μετρήσεις ακρίβειας και ειδικότητας για το μοντέλο ενδέχεται να είναι υπερβολικά κολακευτικές, με αποτέλεσμα την υποτίμηση της αδυναμίας του μοντέλου να ανιχνεύει με ακρίβεια τις κακοήθεις βλάβες. Δημιουργώντας παράλληλα μια ισορροπημένη αναπαράσταση των τύπων δειγμάτων εντός του υποσυνόλου εκπαίδευσης μέσω υπερδειγματοληψίας και σταθμισμένων ταξινομήσεων. Η εκπαίδευση του μοντέλου αποτρέπει την έμφαση μόνο στα κακοήθη δείγματα χωρίς να απομνημονεύει παραδείγματα.

Κεντρικό θέμα σε όλο το κεφάλαιο ήταν η προεπεξεργασία εικόνων και η αύξηση δεδομένων που εφαρμόζουμε στις εικόνες. Για να προετοιμάσουμε το μοντέλο βαθιάς μάθησης για εκπαίδευση, αντί να στείλουμε τις αρχικές εικόνες HAM10000 σε μη επεξεργασμένη μορφή, κάθε μία από τις εικόνες έχει υποστεί επεξεργασία σε τετράγωνο σχήμα, έχει αλλάξει μέγεθος σε ένα σταθερό μέγεθος και έχει υποβληθεί σε ένα πολύ ευρύ φάσμα στοχαστικών μετασχηματισμών (αναστροφή, μικρή περιστροφή, μεγέθυνση/σμίκρυνση, ρύθμιση φωτεινότητας και αντίθεσης, εφαρμογή ελαφριάς θολώσεως, προσομοίωση τεχνημάτων συμπίεσης και, τέλος, επικάλυψη μαλλιών).

Ο σκοπός της εφαρμογής αυτών των μετασχηματισμών είναι να παρέχει στο μοντέλο ρεαλιστικά παραδείγματα των παραλλαγών (ατελειών) που θα αντιμετωπίσει κατά την εξέταση εικόνων που παράγονται από μη εξειδικευμένους χρήστες που χρησιμοποιούν καταναλωτικά προϊόντα. Σε αυτό το κεφάλαιο συζητήθηκαν επίσης ζητήματα γενίκευσης και μεροληψίας στο ευρύτερο πλαίσιο της απόδοσης του μοντέλου και πώς μπορεί να επηρεαστεί από κακές ετικέτες και συναφή μεταδεδομένα.

Η ενότητα για τον εμπλουτισμό του συνόλου δεδομένων υπογραμμίζει επίσης ότι, ενώ το σύνολο δεδομένων HAM10000 θεωρείται ολοκληρωμένο όσον αφορά τους τύπους δέρματος που περιλαμβάνει, υπάρχουν σημαντικά ζητήματα σχετικά με τις διαφορετικές συνθήκες υπό τις οποίες συλλέχθηκαν τα σύνολα δεδομένων. Επιπλέον, η ενότητα που περιγράφει τον τρόπο δημιουργίας του συνόλου δεδομένων με χρήση του TensorFlow υπογράμμισε τον τρόπο με τον οποίο η εννοιολογική άποψη που εξετάζεται σε αυτό το κεφάλαιο μεταφράζεται στην πραγματική υλοποίηση ενός λειτουργικού συνόλου δεδομένων στο TensorFlow (π.χ. πώς μπορεί να κατασκευαστεί ένα DataFrame pandas, πώς να χωριστεί ένα DataFrame για στρωματοποιημένα σύνολα δεδομένων, πώς να κατασκευαστούν αγωγοί για την τροφοδοσία εικόνων από την επαύξηση).

Συνοπτικά, το Κεφάλαιο 3 περιγράφει τις διαδικασίες που χρησιμοποιούνται για την προετοιμασία ενός καθαρού, επισημασμένου και χωρισμένου συνόλου δεδομένων, τον τρόπο με τον οποίο το επαυξημένο σύνολο δεδομένων μπορεί να υποβληθεί σε επεξεργασία ώστε να επιτρέπει την αποτελεσματική τροφοδοσία ενός δικτύου βαθιάς μάθησης βασισμένου στο ConvNeXt-Tiny κατά τη διάρκεια της εκπαίδευσης, και τον τρόπο με τον οποίο αυτές οι διαδικασίες συμβάλλουν στην κατανομή των δεδομένων από τα οποία θα διδαχθεί το μοντέλο. Αυτό απεικονίζεται δείχνοντας πώς το μοντέλο δεν εκπαιδεύεται ποτέ απευθείας από τις αρχικές εικόνες HAM10000, αλλά αντίθετα μαθαίνει από τις παρτίδες εκπαίδευσης των κεντροθετημένων, αναδιαστασιοποιημένων και επαυξημένων εικόνων από ένα στρατηγικά επιμελημένο δείγμα. Έτσι, οι σχεδιαστικές επιλογές που συζητούνται στο Κεφάλαιο 3 είναι κρίσιμες για τον προσδιορισμό του τι μαθαίνει το μοντέλο και της ικανότητας γενίκευσης και της ανθεκτικότητάς του έναντι των ατελειών και παραλλαγών που εμφανίζονται σε εικόνες πραγματικού κόσμου.

Κεφάλαιο 4ο: Αρχιτεκτονική μοντέλου και διαδικασία εκπαίδευσης

Αυτή η ενότητα θα καλύψει το μοντέλο βαθιάς μάθησης που χρησιμοποιήθηκε για την ταξινόμηση των δερματικών βλαβών σε καλοήθεις και κακοήθεις, καθώς και τη διαδικασία εκπαίδευσης που ακολουθήθηκε για την ανάπτυξή του. Η ενότητα αυτή θα επικεντρωθεί στις συγκεκριμένες αρχιτεκτονικές αποφάσεις και τη διαδικασία εκπαίδευσης που συνδέουν τη ροή δεδομένων που συζητήθηκε στο προηγούμενο κεφάλαιο με τα αποτελέσματα και την ανάλυση κατωφλίου. Το μοντέλο υλοποιείται σε TensorFlow και Keras και βασίζεται σε ένα ConvNeXt-Tiny backbone με ένα επιπλέον μπλοκ προσοχής μαζί με μια **συμπαγή** κεφαλή ταξινόμησης.

4.1 Γενική προσέγγιση

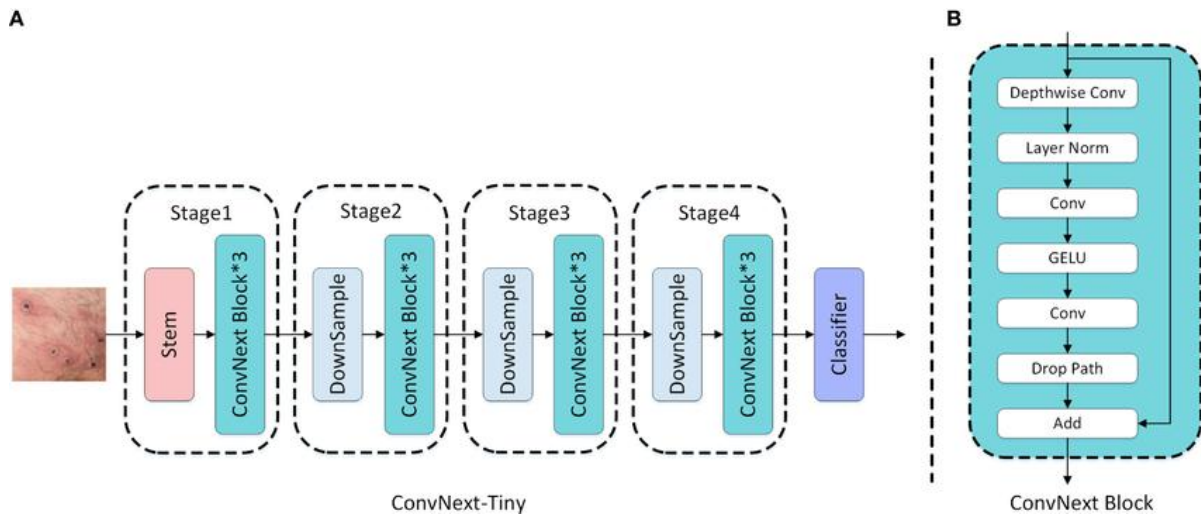
Όπως αναφέρθηκε προηγουμένως, η εργασία ταξινόμησης είναι η πρόβλεψη μιας δυαδικής ετικέτας όπου η θετική κλάση δείχνει την κακοήθη βλάβη και η αρνητική την καλοήθη. Η προσέγγιση που ακολουθήθηκε ήταν η χρήση μιας σύγχρονης αρχιτεκτονικής συνελίξεων που έχει εκπαιδευτεί από πριν σε ένα μεγάλο σύνολο δεδομένων εικόνων γενικού σκοπού (ImageNet) για χρήση ως μηχανισμός εξαγωγής χαρακτηριστικών και η προσαρμογή της στη δυαδική εργασία με την προσθήκη ενός μικρού αριθμού εκπαιδευμένων επιπέδων.

Σε υψηλό επίπεδο, το δίκτυο αποτελείται από τρία κύρια μέρη. Το πρώτο μέρος είναι η ίδια η βασική δομή ConvNeXt-Tiny, η οποία λαμβάνει την εικόνα εισόδου και εξάγει έναν χάρτη χαρακτηριστικών υψηλής διάστασης, που περιέχει τα χωρικά μοτίβα σε πολλαπλές κλίμακες. Το δεύτερο μέρος είναι ένα μπλοκ προσοχής καναλιού που τοποθετείται πάνω από αυτόν τον χάρτη χαρακτηριστικών και σταθμίζει τα κανάλια. Το τρίτο μέρος είναι μια κεφαλή ταξινόμησης, η οποία συμπυκνώνει τον χάρτη εστιασμένης ανάλυσης σε μια ενιαία κλίμακα τιμών μεταξύ μηδέν και ένα, η οποία μπορεί να ερμηνευθεί ως η προβλεπόμενη πιθανότητα κακοήθειας.

Ο συνολικός σχεδιασμός ακολουθεί ένα τυπικό πρότυπο μεταφοράς μάθησης. Αντί να εκπαιδεύεται ένα βαθύ συνελκτικό δίκτυο από το μηδέν σε ένα σχετικά μικρό ιατρικό σύνολο δεδομένων, μια ισχυρή αρχιτεκτονική που έχει προ-εκπαιδευτεί στο μεγάλης κλίμακας σύνολο δεδομένων ImageNet επαναχρησιμοποιείται ως γενικός εξολκέας οπτικών χαρακτηριστικών. Μόνο ένα ρηχό σύνολο πρόσθετων επιπέδων μαθαίνεται ειδικά για το πρόβλημα της δερματοσκοπικής ταξινόμησης. Αυτή η στρατηγική μειώνει σημαντικά τον κίνδυνο υπερπροσαρμογής, μειώνει το υπολογιστικό κόστος και επιτρέπει στο μοντέλο να συγκλίνει αξιόπιστα ακόμη και με περιορισμένο αριθμό κακοήθων παραδειγμάτων.

Η διαδικασία εκπαίδευσης οργανώνεται σε δύο φάσεις. Κατά την αρχική φάση εκπαίδευσης, το backbone διατηρείται παγωμένο, επιτρέποντας την προσαρμογή μόνο των πρόσθετων επιπέδων. Στη δεύτερη φάση, ένα υποσύνολο των βαθύτερων επιπέδων του backbone ξεπαγώνει και ρυθμίζεται με ακρίβεια από κοινού με τα πρόσφατα προστιθέμενα επίπεδα. Αυτή η σταδιακή προσέγγιση καθιστά δυνατή την εκμάθηση μιας σταθερής επιφάνειας απόφασης στον χώρο των προ-εκπαιδευμένων χαρακτηριστικών και μόνο τότε την προσαρμογή της υψηλού επιπέδου αναπαράστασης των δερματοσκοπικών εικόνων με πιο στοχευμένο τρόπο.

Στο πλαίσιο του συνολικού συστήματος που περιγράφεται στη διατριβή, το Κεφάλαιο 4 αποτελεί τον πυρήνα του μοντέλου που βρίσκεται μεταξύ της ροής δεδομένων του Κεφαλαίου 3 και των διαδικασιών αξιολόγησης και επιλογής κατωφλίου που θα παρουσιαστούν στο Κεφάλαιο 5. Μόλις καθοριστεί η αρχιτεκτονική και η διαδικασία εκπαίδευσης, όλα τα επόμενα βήματα μετρήσεις επικύρωσης, κατώφλια λειτουργίας, ζώνες κινδύνου και ανάπτυξη σε κινητά εξαρτώνται άμεσα από τη συμπεριφορά αυτού του ταξινομητή.



Σχήμα 4.1: Αρχιτεκτονική convnext-tiny[3]

4.2 Βασική γραμμή ConvNeXt-Tiny και προδιαγραφές εισόδου

Η βασική αρχιτεκτονική του μοντέλου είναι η βασική γραμμή ConvNeXt-Tiny, ένα μοντέλο συνελκτικής συνάρτησης που έχει αποδείξει ανταγωνιστική απόδοση για εργασίες ταξινόμησης εικόνων μεγάλης κλίμακας. Το ConvNeXt έχει πρόσφατα προταθεί ως μια «εκσυγχρονισμένη» συνελκτική αρχιτεκτονική που προσφέρει απόδοση παρόμοια με αυτή των σύγχρονων Vision Transformers σε καθήκοντα ταξινόμησης μεγάλων εικόνων [16]. Στην εφαρμογή αυτού του άρθρου, η βασική αρχιτεκτονική φορτώθηκε με βάρη που είχαν προ-εκπαιδευτεί στο ImageNet και διαμορφώθηκε χωρίς την αρχική κεφαλή ταξινόμησης. Το δίκτυο υλοποιήθηκε χωρίς αρχική κεφαλή ταξινόμησης με ενεργοποιημένη την εσωτερική προ-επεξεργασία. Όταν το `include_top` είναι off, αυτή η διαμόρφωση υποδηλώνει ότι το μοντέλο εξάγει έναν χάρτη χαρακτηριστικών αντί για logits κλάσης στα επίπεδα εξόδου - η ενεργοποίηση της προεπεξεργασίας σημαίνει ότι το δίκτυο μπορεί να λάβει απευθείας τις ακατέργαστες τιμές pixel ως είσοδο και να εφαρμόσει εσωτερικά τα κατάλληλα επίπεδα κανονικοποίησης.

Η είσοδος στο backbone είναι ένας ταυστής εικόνας RGB με σχήμα 256 x 256 pixel με τρία κανάλια, ο οποίος ταιριάζει με την έξοδο από τον αγωγό προεπεξεργασίας που περιγράφεται στο Κεφάλαιο 3. Στη συνέχεια, η βάση ConvNeXt-Tiny χρησιμοποιεί αυτόν τον ταυστή ως είσοδο και τον περνάει από πολλαπλά μπλοκ συνελίξεων που έχουν διαφορετικά επίπεδα υποδειγματοληψίας και, στη συνέχεια, εξάγει έναν τελικό χάρτη χαρακτηριστικών που έχει μειωμένες χωρικές διαστάσεις και αυξημένο αριθμό καναλιών. Ο τελικός χάρτης χαρακτηριστικών μετά τη βασική γραμμή ConvNeXt-Tiny χρησιμοποιείται ως βάση για τον μηχανισμό προσοχής και την κεφαλή ταξινόμησης.

Στην πρώτη φάση της εκπαίδευσης, η βασική γραμμή παραμένει παγωμένη, καθώς τα βάρη είναι σταθερά ακριβώς στις προ-εκπαιδευμένες τιμές τους. Αυτό επιτρέπει και στα δύο στρώματα που προστέθηκαν πρόσφατα στην κορυφή να μάθουν σημαντικούς συνδυασμούς των χαρακτηριστικών που προέρχονται από τη βασική γραμμή, χωρίς άμεσες αλλαγές στην αρχική αρχιτεκτονική. Σε μια επόμενη φάση λεπτομερούς ρύθμισης, ξεπαγώνουμε και προσαρμόζουμε ένα υποσύνολο των βαθύτερων στρωμάτων στη βασική δομή, βοηθώντας το μοντέλο να προσαρμοστεί καλύτερα στους δερματοσκοπικούς τομείς διατηρώντας παράλληλα ισχυρές αναπαραστάσεις που έχουν μαθευτεί από τα προηγούμενα στρώματα.


Ο κορμός ConvNeXt-Tiny για την έρευνα αυτή είναι μια έκδοση του API `tf.keras.applications.ConvNeXtTiny`, το οποίο έχει δημιουργηθεί χωρίς να περιλαμβάνεται η κεφαλή ταξινόμησης ImageNet και, αντ' αυτού, παράγει έναν πυκνό χάρτη χαρακτηριστικών που διατηρεί μέρος της μειωμένης χωρικής διάταξης και πολλά κανάλια. Το ενσωματωμένο βήμα προεπεξεργασίας επιτρέπει στο μοντέλο να δέχεται ένταση pixel σε μορφή raw μεταξύ [0, 255] και να εφαρμόζει την ίδια

κανονικοποίηση που χρησιμοποιήθηκε όταν το μοντέλο προ-εκπαιδεύτηκε με το ImageNet. Αυτό σημαίνει ότι οι χρήστες δεν χρειάζεται να αναδιαμορφώσουν ή να κανονικοποιήσουν χειροκίνητα τα δεδομένα τους και θα έχουν μια συνεπή συμπεριφορά μοντέλου μεταξύ Keras και TensorFlow Lite.

Η είσοδος στο backbone αντιστοιχεί στη μορφή εικόνων που παράγεται από τον αγωγό προεπεξεργασίας του Κεφαλαίου 3. Μόλις εισαχθεί στο ConvNeXt-Tiny stack των μπλοκ συνελίξεων, η χωρική διάταξη της εισόδου μειώνεται διαδοχικά χρησιμοποιώντας συνελίξεις strided, και ο αριθμός των καναλιών αυξάνεται διαδοχικά. Επομένως, ο τελικός χάρτης χαρακτηριστικών αντιπροσωπεύει την χωρικά μειωμένη αρχική εικόνα, αλλά περιέχει έναν σημαντικά μεγαλύτερο αριθμό καναλιών και αντιπροσωπεύει μια συμπυκνωμένη αναπαράσταση μοτίβων υψηλότερου επιπέδου (π.χ. δίκτυα χρωστικών, σφαιρίδια, ραβδώσεις, αρχιτεκτονικές ασυμμετρίες).

Το ConvNeXt-Tiny είναι μια «εκσυγχρονισμένη» αρχιτεκτονική συνελίξεων που απέκτησε διάφορα βασικά χαρακτηριστικά σχεδιασμού από τα Vision Transformers (π.χ. μεγάλα μεγέθη πυρήνων και απλοποιημένη δομή μπλοκ), διατηρώντας παράλληλα τους επαγωγικούς περιορισμούς των συνελκτικών δικτύων. Μέσω συγκριτικών δοκιμών ταξινόμησης εικόνων μεγάλης κλίμακας, τόσο η οικογένεια ConvNeXt όσο και τα μοντέλα Transformer έχουν επιτύχει συγκρίσιμη απόδοση. Ωστόσο, οι αρχιτεκτονικές ConvNeXt μπορούν να εφαρμοστούν στα τρέχοντα πλαίσια βαθιάς μάθησης, καθιστώντας τις επιθυμητές αρχιτεκτονικές για μοντέλα ταξινόμησης ιατρικών εικόνων που πρέπει να εξαχθούν στο TensorFlow Lite και να λειτουργούν αποτελεσματικά σε κινητό υλικό.

Αν και η βασική αρχιτεκτονική που χρησιμοποιείται στο παρόν μοντέλο δεν τροποποιήθηκε, είναι δυνατή η πρόσβαση και η επαναχρησιμοποίησή της σε κατάσταση παγωμένη (μη εκπαιδευμένη) ή μερικώς εκπαιδευμένη (μπορεί να εκπαιδευτεί ένα μικρό ποσοστό των επιπέδων). Αυτό αποτελεί ένα σημαντικό βήμα προς την αναπαραγωγιμότητα μελλοντικών εργασιών, καθώς επιτρέπει στους ερευνητές να μεταβάλλουν τον μηχανισμό προσοχής ή την κεφαλή ταξινόμησης, διατηρώντας παράλληλα το βασικό επίπεδο ανέπαφο, ή να αντικαταστήσουν την βασική αρχιτεκτονική με ένα άλλο προ-εκπαιδευμένο μοντέλο, χρησιμοποιώντας τα ίδια επίπεδα προβολής.



Σχήμα 4.2: Μπλοκ Squeeze and Excitation που υπολογίζει βάρη προσοχής ανά κανάλι και ανασταθμίζει του χάρτη χαρακτηριστικών

4.3 Προσοχή στο κανάλι με συμπίεση και διέγερση

Μετά τον κορμό ConvNeXt-Tiny, εφαρμόζουμε μια στρατηγική προσοχής στο κανάλι, χρησιμοποιώντας ένα μπλοκ συμπίεσης και διέγερσης, για να επιτρέψουμε στο δίκτυο να ενισχύσει πιο ενημερωτικά κανάλια στο χάρτη χαρακτηριστικών για την εργασία ταξινόμησης, ενώ ταυτόχρονα μειώνει τα λιγότερο πληροφοριακά κανάλια με βάση μια συνολική σύνοψη ανά κανάλι, η οποία προκύπτει μέσω ολικής μέσης συγκέντρωσης (global average pooling). Τα μπλοκ Squeeze-and-Excitation εισήχθησαν αρχικά ως μια γενική προσθήκη σε ήδη υπάρχουσες συνελκτικές

αρχιτεκτονικές, επιτυγχάνοντας σημαντικές βελτιώσεις στην ακρίβεια με ελάχιστο πρόσθετο υπολογιστικό κόστος [17].

Το μπλοκ συμπίεσης και διέγερσης μπορεί να θεωρηθεί ότι συμβαίνει σε τρία στάδια. Πρώτον, εφαρμόζουμε συνολική μέση συγκέντρωση ανεξάρτητα σε κάθε κανάλι του χάρτη χαρακτηριστικών. Η συνολική μέση συγκέντρωση παράγει ένα διάνυσμα με διάσταση ίση με τον αριθμό των καναλιών στον χάρτη χαρακτηριστικών. Κάθε στοιχείο διανύσματος εμφανίζει τη μέση ενεργοποίηση ενός μεμονωμένου καναλιού σε όλες τις χωρικές θέσεις, η οποία μπορεί να ερμηνευθεί ως ένα συνοπτικό μέτρο του πόσο έντονα ανταποκρίθηκε το κανάλι στην τρέχουσα εικόνα.

Δεύτερον, ο φορέας μεταφέρεται σε ένα μικρό δίκτυο προώθησης. Συγκεκριμένα, στην περίπτωση μας, το διάνυσμα τροφοδοτείται σε πυκνό επίπεδο που μειώνει τη διαστατικότητα κατά έναν σταθερό συντελεστή, χρησιμοποιώντας την συνάρτηση ενεργοποίησης ReLU (Rectified Linear Unit). Η μείωση λειτουργεί ως εμπόδιο που παρακινεί τον μηχανισμό προσοχής να συνοψίσει τις συμπαγείς εξαρτήσεις ανά κανάλι. Τέλος, η αρχική διαστατικότητα του καναλιού αποκαθίσταται από το πυκνό στρώμα με σιγμοειδή ενεργοποίηση. Το αποτέλεσμα είναι ένα σύνολο βαρών προσοχής που κυμαίνονται από 0 έως 1, ένα για κάθε κανάλι.

Στη συνέχεια, τα βάρη προσοχής αναδιαμορφώνονται και μεταδίδονται πίσω στην αρχική τους μορφή του χάρτη χαρακτηριστικών και, στη συνέχεια, πολλαπλασιάζονται με τον χάρτη χαρακτηριστικών ανά κανάλι. Τα κανάλια με συντελεστές προσοχής που είναι κοντά στο 1 παραμένουν, ενώ τα κανάλια με συντελεστές που είναι κοντά στο 0 μειώνονται. Το αποτέλεσμα είναι ένας χάρτης χαρακτηριστικών προσοχής που καταγράφει τόσο τα αρχικά χωρικά μοτίβα και την συνολική προσοχή του κάθε καναλιού που προσαρμόζεται με βάση τα δεδομένα εκπαίδευσης. Αυτός ο χάρτης χαρακτηριστικών προσοχής μεταβιβάζεται στη συνέχεια στην κεφαλή ταξινόμησης.

Μετά την απόκτηση του διανύσματος προσοχής, αυτό αναδιαμορφώνεται σε μορφή $[[1, 1, C]]$ και πολλαπλασιάζεται με τον χάρτη χαρακτηριστικών CONVNEXT στον άξονα καναλιού. Αυτό επιτρέπει στο μοντέλο να δώσει πρόσθετη προσοχή στα κανάλια χαρακτηριστικών που παράγουν ισχυρές συνολικές περιλήψεις σχετικά με κακοήθεις χαρακτηριστικά, ενώ μειώνει τη βαρύτητα των καναλιών που είναι πιθανό να ενεργοποιηθούν λόγω άσχετων τεχνημάτων ή καλοήθων δομών. Η ένταση της προσοχής σε κάθε κανάλι μαθαίνεται ταυτόχρονα με όλους τους άλλους παραμέτρους του δικτύου και προσαρμόζεται με την πάροδο του χρόνου στην κατανομή των δερματοσκοπικών εικόνων, ακόμη και αν η ραχοκοκαλιά CONVNEXT έχει εκπαιδευτεί σε εικόνες φυσικών σκηνών.

Η διαμόρφωση του SE Block παράγει έναν σχετικά μικρό αριθμό πρόσθετων βαρών σε σύγκριση με τις προηγούμενες ραχοκοκαλιές που περιγράφονται σε αυτή τη μελέτη και, σε πολλές περιπτώσεις, παρουσιάζει αυξημένη απόδοση στην ταξινόμηση. Συγκεκριμένα, στο πλαίσιο της προτεινόμενης εργασίας, το SE Block παρέχει έναν μηχανισμό προσαρμογής μεταξύ των γενικών αναπαραστάσεων του ImageNet και του δυαδικού ταξινομητή και δίνει έμφαση στα κανάλια χαρακτηριστικών που είναι ιδιαίτερα ωφέλιμα για τον διαχωρισμό των κακοήθων από τις καλοήθεις βλάβες, αναδιαμορφώνοντας έτσι τη ροή πληροφοριών προς τα πυκνά στρώματα πριν από την ταξινόμηση. Επιπλέον, η αποτελεσματικότητα της χρήσης της διαμόρφωσης SE Block επιτρέπει την απόκτηση πολλών πλεονεκτημάτων, μειώνοντας ταυτόχρονα σημαντικά το υπολογιστικό φορτίο της λειτουργίας του μοντέλου σε κινητές συσκευές όπου υπάρχουν πολλοί περιορισμοί.

4.4 Κεφαλή ταξινόμησης

Η κεφαλή ταξινόμησης που έχει δημιουργηθεί πάνω στον χάρτη χαρακτηριστικών με στάθμιση προσοχής ακολουθεί μια σκόπιμη απλή δομή. Πρώτον, ένα στρώμα συνολικής μέσης συγκέντρωσης συμπίεζει τις χωρικές διαστάσεις, παράγοντας ένα ενιαίο διάνυσμα χαρακτηριστικών ανά εικόνα. Αυτή η επιλογή εξασφαλίζει ότι ο ταξινομητής είναι αμετάβλητος σε μικρές μετατοπίσεις εντός του πεδίου

υποδοχής της ραχοκοκαλιάς και μειώνει σημαντικά τον αριθμό των παραμέτρων σε σύγκριση με τη χρήση ενός πλήρως συνδεδεμένου στρώματος σε όλες τις χωρικές θέσεις.

Ο συγκεντρωμένο διάνυσμα στη συνέχεια περνάει από ένα πυκνό στρώμα με 128 μονάδες και ενεργοποίηση ReLU, ακολουθούμενο από ένα στρώμα απόρριψης με πιθανότητα απόρριψης 0,5. Το 128-διάστατο ενδιάμεσο επίπεδο λειτουργεί ως στενό σημείο (bottleneck) επιτυγχάνοντας ισορροπία μεταξύ εκφραστικής ισχύος και αποφυγής υπερπροσαρμογής. Αυτό αντιπροσωπεύει μη γραμμικούς συνδυασμούς των χαρακτηριστικών του βασικού πλαισίου του backbone που είναι σχετικοί με την κακοήθεια, αλλά αρκετά μικρά για να αποθαρρύνει το μοντέλο από το να απομνημονεύει μεμονωμένα παραδείγματα εκπαίδευσης. Το dropout μειώνει περαιτέρω την υπερπροσαρμογή, μηδενίζοντας τυχαία ένα υποσύνολο ενεργοποιήσεων σε κάθε βήμα εκπαίδευσης, αναγκάζοντας το δίκτυο να κατανέμει τις πληροφορίες σε πολλαπλές μονάδες αντί να βασίζεται σε λίγους εξειδικευμένους νευρώνες.

Το τελικό στρώμα είναι ένα πυκνό στρώμα μίας μονάδας με σιγμοειδή ενεργοποίηση, που παράγει ένα σκαλάρ μεταξύ 0 και 1 που ερμηνεύεται ως η προβλεπόμενη πιθανότητα ότι η βλάβη είναι κακοήθης. Αυτή η διατύπωση ευθυγραμμίζεται φυσικά με τη δυαδική απώλεια διασταυρούμενης εντροπίας και καθιστά εύκολη την εφαρμογή διαφορετικών ορίων απόφασης κατά την αξιολόγηση ή την ανάπτυξη. Στα επόμενα κεφάλαια θα αξιοποιηθεί αυτή η ιδιότητα για να μελετηθεί η σχέση μεταξύ ευαισθησίας και ειδικότητας σε ένα συνεχές φάσμα ορίων και να οριστούν ζώνες χαμηλού, μέσου και υψηλού κινδύνου που αντιστοιχούν τα αποτελέσματα του μοντέλου σε μηνύματα που απευθύνονται στους χρήστες.

4.5 Συνάρτηση απώλειας, μετρήσεις και βελτιστοποίηση

Το μοντέλο εκπαιδεύεται με δυαδική απώλεια διασταυρούμενης εντροπίας ως κύρια συνάρτηση απώλειας. Η δυαδική διασταυρούμενη εντροπία περιγράφει πόσο μακριά βρίσκεται η προβλεπόμενη πιθανότητα από την πραγματική δυαδική ετικέτα και χρησιμοποιείται συνήθως για προβλήματα ταξινόμησης δύο κατηγοριών. Στην απώλεια, εφαρμόζονται βάρη κατηγοριών για να αντιπροσωπεύσουν τη μεγαλύτερη σημασία των κακοήθων βλαβών, πράγμα που σημαίνει ότι τα σφάλματα στα κακοήθη δείγματα σταθμίζονται περισσότερο από τα σφάλματα στα καλοήθη δείγματα. Τα βάρη υπολογίστηκαν με βάση τις συχνότητές εμφάνισης των κλάσεων στην διαδικασία της εκπαίδευσης.

Εκτός από την απώλεια, παρακολουθούνται διάφοροι δείκτες για την αξιολόγηση της απόδοσης του μοντέλου κατά τη διάρκεια της εκπαίδευσης. Παρακολουθούνται η ευαισθησία (ονομάζεται επίσης ανάκληση για κακοήθης βλάβες), η ειδικότητα, η ακρίβεια και η περιοχή κάτω από την καμπύλη χαρακτηριστικών λειτουργίας του δέκτη. Η ευαισθησία είναι ένας σημαντικός δείκτης σε αυτό το πλαίσιο, επειδή είναι κλινικά χειρότερο να παραβλέπεται μια κακοήθης βλάβη παρά να ταξινομείται λανθασμένα μια καλοήθης βλάβη. Αν και αυτό έχει κάποια σημασία, η ειδικότητα είναι επίσης σημαντική, καθώς η χαμηλή ειδικότητα σημαίνει ότι θα προκύψουν πολλά ψευδώς θετικά αποτελέσματα. Η επιφάνεια που βρίσκεται κάτω από την καμπύλη ROC είναι ένα μέτρο που δεν εξαρτάται από το κατώφλι και αξιολογεί πόσο καλά το μοντέλο μπορεί να διαχωρίζει τις κακοήθεις βλάβες από τις καλοήθεις.

Κατά τη διαδικασία της εκπαίδευσης, η δυαδική διασταυρούμενη απώλεια εντροπίας συγκρίνει τις προβλεπόμενες πιθανότητες κακοήθειας με τις πραγματικές ετικέτες κακοήθειας ή καλοήθειας για κάθε δείγμα. Λόγω της μεγάλης ανισορροπίας των κατηγοριών που παρατηρείται στο σύνολο δεδομένων HAM10000, θα χρησιμοποιηθεί μια μέθοδος στάθμισης κατηγοριών, στην οποία οι σταθμίσεις κατηγοριών που αποδόθηκαν κατά τη φάση διαχωρισμού της εκπαίδευσης καθορίστηκαν με βάση την αναλογία των καλοήθων παραδειγμάτων προς τα κακοήθη παραδείγματα. Ουσιαστικά, τα καλοήθη παραδείγματα θα έχουν βάρος 1,0, ενώ τα κακοήθη παραδείγματα θα έχουν βάρος μεγαλύτερο από 1,0, ίσο με την αναλογία του αριθμού των καλοήθων προς τα κακοήθη δείγματα. Αυτό σημαίνει ότι τα σφάλματα που γίνονται σε ένα κακοήθες δείγμα θα τιμωρούνται πιο αυστηρά από ένα καλοήθες σφάλμα

και ενθαρρύνει το δίκτυο να επικεντρώσει την ευαισθησία του στα κακοήθη δείγματα χωρίς να εγκαταλείψει όλη την ειδικότητα.

Για την εκπαίδευση του μοντέλου, θα χρησιμοποιηθεί ο βελτιστοποιητής προσαρμοστικής εκτίμησης ροπής που ονομάζεται AdamW. Ο AdamW διαχωρίζει τη λειτουργία αποσβέσεως βάρους από τη λειτουργία κατάβασης κλίσης και έχει αποδειχθεί ότι παρέχει πιο σταθερή σύγκλιση από τις παραδοσιακές μεθόδους κανονικοποίησης L2 όταν συνδυάζεται με τον Adam, ειδικά για βαθιές αρχιτεκτονικές. Σε αυτό το έργο, το AdamW θα παρέχει υψηλό ρυθμό μάθησης όταν τα μόνα εξαρτήματα που μπορούν να εκπαιδευτούν είναι η κεφαλή ταξινόμησης και το μπλοκ προσοχής κατά τη φάση ένα και μικρότερο ρυθμό μάθησης όταν το τελευταίο τμήμα της ραχοκοκαλιάς ρυθμίζεται με ακρίβεια στη φάση δύο. Αυτό το πρόγραμμα ρυθμού μάθησης επιτρέπει τη γρήγορη προσαρμογή των προστεθειμένων επιπέδων, περιορίζοντας παράλληλα τις ενημερώσεις που γίνονται στα εκπαιδευμένα συνελκτικά φίλτρα.

Διάφορες μετρήσεις θα παρακολουθούνται καθ' όλη τη διάρκεια της εκπαίδευσης και της αξιολόγησης. Το μοντέλο θα αξιολογηθεί χρησιμοποιώντας την περιοχή κάτω από την καμπύλη ROC (AUC), το AUC και την επιθυμητή ευαισθησία και ειδικότητα σε ένα όριο 0,5. Επιπλέον, μια εναλλακτική συνάρτηση αξιολόγησης θα λειτουργεί στο σύνολο επικύρωσης για τον υπολογισμό του AUC, της ευαισθησίας, της ειδικότητας και της ακρίβειας με σκοπό την αξιολόγηση του μοντέλου και θα χρησιμοποιείται από τη λογική επιστροφής κλήσης πρόωρης διακοπής για να καθοριστεί εάν το μοντέλο έχει δείξει βελτίωση ή όχι. Η λογική πρόωρης διακοπής θα παρέχει ταυτόχρονα το AUC και την ευαισθησία. Επομένως, η εκπαίδευση θα συνεχιστεί όσο βελτιώνεται οποιαδήποτε από αυτές τις τιμές, γεγονός που δίνει προτεραιότητα στην εκπαίδευση μοντέλων που διατηρούν υψηλή διακριτικότητα και ανιχνεύουν όσο το δυνατόν περισσότερα κακοήθη δείγματα.

Κατά την επιλογή των μετρήσεων, θα πρέπει να λαμβάνονται υπόψη οι κλινικές επιπτώσεις των μετρήσεων που χρησιμοποιούνται. Για παράδειγμα, η αξιολόγηση της ακρίβειας από μόνη της μπορεί να είναι παραπλανητική στην περίπτωση μη ισορροπημένων δεδομένων, καθώς ένα μοντέλο που προβλέπει καλοήθη δείγματα θα επιτύχει υψηλή βαθμολογία ακρίβειας, αλλά δεν θα έχει ευαισθησία. Το AUC καταγράφει πόσο καλά το μοντέλο κατατάσσει τα κακοήθη δείγματα πάνω από τα καλοήθη δείγματα σε όλα τα όρια, ενώ τόσο η ευαισθησία όσο και η ειδικότητα παρέχουν πιο άμεσα ερμηνεύσιμα μέτρα της απόδοσης του μοντέλου με βάση την επιλογή ενός συγκεκριμένου ορίου λειτουργίας. Επομένως, η ανάλυση των μετρήσεων που χρησιμοποιούνται στην εκπαίδευση και βελτιστοποίηση των μοντέλων σε αυτό το κεφάλαιο συνδέεται στενά με την ανάλυση επιλογής κατωφλίου που περιγράφεται στο Κεφάλαιο 5.

4.6 Σχέδιο εκπαίδευσης και πρόωρος τερματισμός

Η εκπαίδευση πραγματοποιείται σε δύο στάδια. Στο πρώτο στάδιο, τα βάρη του ConvNeXt backbone παραμένουν παγωμένα και εκπαιδεύονται μόνο τα στρώματα που προστίθενται μετά από αυτό. Αυτά τα στρώματα είναι το μπλοκ συμπίεσης-διέγερσης και η κεφαλή ταξινόμησης. Το μοντέλο έχει τη δυνατότητα να εκπαιδευτεί για έναν μέγιστο αριθμό εποχών που καθορίζεται πριν από την εκπαίδευση. Η διαδικασία εκπαίδευσης μπορεί να σταματήσει νωρίτερα εάν πληρούνται μια προκαθορισμένη συνθήκη πρόωρης διακοπής βασισμένη στις μετρήσεις επικύρωσης.

Στη δεύτερη φάση, ένα σύνολο στρωμάτων στα βαθύτερα στρώματα των συνελκτικών νευρωνικών δικτύων που χρησιμοποιούνται στη δομή ConvNeXt δεν είναι παγωμένα. Κατά τη διάρκεια αυτής της φάσης, αυτά τα στρώματα εκπαιδεύονται για να προσαρμοστούν στα χαρακτηριστικά των δερματοσκοπικών εικόνων. Κατά τη δεύτερη φάση, ο ρυθμός μάθησης μειώνεται για να επιτευχθεί ρύθμιση υψηλής ακρίβειας των προ εκπαιδευμένων βαρειών. Η λεπτή ρύθμιση πραγματοποιείται με μειωμένο ρυθμό μάθησης, καθώς τα βάρη είναι προ-εκπαιδευμένα.

Η πρόωρη διακοπή για τον έλεγχο της σύγκλισης γίνεται με την παρακολούθηση των μετρήσεων επικύρωσης μετά από κάθε σύνολο εποχών. Η διαδικασία πρόωρης διακοπής δεν βασίζεται αποκλειστικά σε μία μέτρηση αλλά χρησιμοποιεί έναν συνδυαστικό μηχανισμό πρόωρης διακοπής βασισμένο σε περισσότερες από μία μετρικές επικύρωσης. Η μέθοδος σταματά την εκπαίδευση εάν δεν υπάρχει βελτίωση για μια μικρή ανοχή που καθορίζεται σε έναν καθορισμένο αριθμό εποχών σχετικά με τις δύο προαναφερθείσες συνθήκες. Ο στόχος της διαδικασίας είναι η αποφυγή υπερπροσαρμογής στα δεδομένα εκπαίδευσης και η αποτροπή άσκοπης υπολογιστικής δαπάνης μετά τη σύγκλιση.

Στη Φάση 1, ολόκληρο το ConvNeXt-Tiny backbone παραμένει στατικό, ενώ ενημερώνονται μόνο το SE Block και τα πυκνά στρώματα. Η μέγιστη εκπαίδευση εποχής για αυτή τη φάση είναι σταθερή, ωστόσο, εάν τεθεί σε εφαρμογή μια συνθήκη πρόωρης διακοπής, η εκπαίδευση μπορεί να ολοκληρωθεί πριν φτάσει στο καθορισμένο μέγιστο όριο εποχής. Κατά τη διάρκεια αυτής της φάσης, στο τέλος της εκπαίδευσης, μια συνάρτηση επανάκλησης (callback) επιτρέπει την επαναφορά των βαρών από την εποχή που πέτυχε την εποχή που παρουσίασε τη βέλτιστη απόδοση ως προς AUC επικύρωσης και ευαισθησία, σύμφωνα με τα κριτήρια της συνάρτησης πρόωρης διακοπής. Επομένως, το μοντέλο που θα χρησιμοποιηθεί ως βάση για τη ρύθμιση του πυρήνα είναι ήδη αρκετά καλό στο σύνολο δεδομένων επικύρωσης.

Κατά τη διάρκεια της Φάσης 2, η τελική ομάδα στρωμάτων του ConvNeXt-Tiny backbone θα ξεπαγώσει και θα επισημανθεί ως εκπαιδευσιμο. Ο πραγματικός αριθμός της τελικής ομάδας εκπαιδευτέων στρωμάτων backbone θα καθορίζεται από έναν υπερπαραμέτρο, ο οποίος ορίζεται σε 30 εκπαιδευσιμα στρώματα από το τέλος του backbone, βάσει εριστικής διερεύνησης, ώστε να επιτρέπεται η προσαρμογή των αναπαραστάσεων χαρακτηριστικών υψηλού επιπέδου, διατηρώντας παράλληλα τα φίλτρα χαμηλότερου επιπέδου.

Μετά την επανασυγκρότηση του μοντέλου χρησιμοποιώντας χαμηλότερο ρυθμό μάθησης, η εκπαίδευση μπορεί να συνεχιστεί χρησιμοποιώντας την ίδια συνάρτηση επιστροφής πρόωρης διακοπής που παρακολουθεί τη συνολική απόδοση και των τριών τμημάτων αυτού του μοντέλου - του μερικώς εκπαιδευμένου backbone, του μπλοκ προσοχής και της κεφαλής ταξινόμησης.

Τηρώντας τη λογική πρόωρης διακοπής της συνάρτησης DualEarlyStopper Callback, η κλήση ελέγχει εάν η τιμή AUC ή η τιμή ευαισθησίας έχει βελτιωθεί σε σχέση με τις προηγούμενες καλύτερες τιμές που έχουν παρατηρηθεί και, εάν αυτό ισχύει, αποθηκεύει τα βάρη του μοντέλου στη μνήμη και επαναφέρει τον μετρητή υπομονής. Εάν ούτε η AUC ούτε η ευαισθησία βελτιωθούν, τότε η κλήση θα αυξήσει τον μετρητή κατά ένα, εάν ο αριθμός των εποχών χωρίς βελτιώσεις πληροί ένα προκαθορισμένο όριο. Μόλις επιτευχθεί το προκαθορισμένο όριο, η κλήση επιστροφής θα θέσει μια σημαία για να σταματήσει την εκπαίδευση. Μετά την ολοκλήρωση της Φάσης 2, η κλήση επιστροφής DualEarlyStopper θα επαναφέρει το καλύτερο βάρος και θα επιστρέψει τον έλεγχο στο κύριο σενάριο. Αυτό επιτρέπει την αποφυγή υπερπροσαρμογής στα δεδομένα εκπαίδευσης, μειώνει τον χρόνο που χάνεται για την εκπαίδευση του μοντέλου μόλις σταθεροποιηθεί η απόδοση στα δεδομένα επικύρωσης.

4.7 Εξερεύνηση πρακτικών ζητημάτων ανάπτυξης εκπαίδευσης προσανατολισμένης στην ανάπτυξη

Όπως αναφέρθηκε προηγουμένως, εκτός από την εννοιολογική αρχιτεκτονική και τη διαδικασία εκπαίδευσης, πρέπει επίσης να ληφθεί υπόψη η κατάσταση ανάπτυξης κατά τη λήψη αποφάσεων σχετικά με το σχεδιασμό κάθε μέρους του συστήματος εκπαίδευσης. Η τελική έκδοση του μοντέλου που περιγράφεται στην παρούσα διατριβή θα εξαχθεί τελικά στο TensorFlow Lite και θα εκτελεστεί σε καταναλωτικά smartphone που εκτελούν μια εφαρμογή Flutter, αντί να υπάρχει αποκλειστικά σε ερευνητικό περιβάλλον. Επομένως, αυτή η απαίτηση επηρέασε πολλούς διαφορετικούς τομείς του σχεδιασμού τόσο για την αρχιτεκτονική όσο και για την εκπαίδευση του μοντέλου.

Για παράδειγμα, λόγω της σημασίας της διατήρησης του υπολογιστικού κόστους σε χαμηλά επίπεδα για την εκπαίδευση με γνώμονα την ανάπτυξη, επιλέξαμε την αρχιτεκτονική ConvNeXt-Tiny αντί για μια μεγαλύτερη ή βαρύτερη αρχιτεκτονική βασισμένη σε μετασηματιστή. Η αρχιτεκτονική ConvNeXt-Tiny έχει δεκάδες εκατομμύρια παραμέτρους, αλλά δημιουργεί πολύ μικρότερο υπολογιστικό φορτίο από άλλα παρόμοια μοντέλα που συνήθως αναφέρονται ως «τελευταίας τεχνολογίας», και το μοντέλο εφαρμογής που αναπτύχθηκε από το TensorFlow παρέχει άμεση υποστήριξη μέσω του TensorFlow για την αρχιτεκτονική ConvNeXt-Tiny. Έτσι, όταν προσθέσαμε ένα μόνο μπλοκ SE και ένα μικρό πυκνό κεφάλι πάνω από την αρχιτεκτονική ConvNeXt-Tiny, προσθέσαμε πολύ λίγα σε όρους πρόσθετου κόστους στο μοντέλο, λόγω της χρήσης μόνο μικρού αριθμού πρόσθετων παραμέτρων. Η εξισορρόπηση μεταξύ του μεγέθους του μοντέλου και του υπολογιστικού κόστους συνεχίζεται καθώς μετατρέπουμε το ολοκληρωμένο ConvNeXt-Tiny σε διαφορετικούς τύπους μοντέλων TensorFlow Lite, όπως το μοντέλο πλήρους ακρίβειας κινητής υποδιαστολής και διάφορα κβαντισμένα μοντέλα που παρέχουν δυναμικό εύρος και/ή μειωμένη ακρίβεια, χωρίς να υπερβαίνουμε τα όρια του κινητού υλικού.

Επιπλέον, όταν το μοντέλο ConvNeXt-Tiny εκτελείται εκτός του περιβάλλοντος εκπαίδευσής του, είναι ιδιαίτερα επωφελές να χρησιμοποιήσετε το `include_preprocessing=True` στο backbone του ConvNeXt-Tiny για να μειώσετε τον χρόνο που απαιτείται για την προεπεξεργασία των δεδομένων εισόδου από την κινητή συσκευή του τελικού χρήστη πριν από την αποστολή τους στο εκπαιδευμένο μοντέλο. Το μοντέλο Keras και το μοντέλο TensorFlow Lite αναμένουν ότι οι εικόνες θα έχουν έναν τανυστή εισόδου ενός χρωματικού χώρου RGB, όπου οι τιμές RGB βρίσκονται σε ένα εύρος από 0 έως 255, με βάση τον τρόπο με τον οποίο αντιπροσωπεύονται ως τιμές κινητής υποδιαστολής. Επομένως, εφαρμόζουν την ίδια προεπεξεργασία για τις εικόνες όταν τις μεταβιβάζουν στο μοντέλο. Και οι δύο εφαρμογές μπορούν να χρησιμοποιούν τα ίδια σενάρια προεπεξεργασίας κατά την εκπαίδευση και την ανάπτυξη ενός μοντέλου, επειδή όλες οι εικόνες περικλύονται στο κέντρο και αλλάζουν μέγεθος στις ίδιες διαστάσεις 256 pixel x 256 pixel, μετατρέπονται σε τανυστή float32 και στη συνέχεια τροφοδοτούνται απευθείας στο μοντέλο. Αυτό έχει ως αποτέλεσμα μικρότερο κίνδυνο ανισοτήτων στην προεπεξεργασία, με αποτέλεσμα μειωμένη απόδοση από τη στιγμή της εκπαίδευσης έως την ανάπτυξη.

Δεύτερον, η διαδικασία εκπαίδευσης σε δύο στάδια αναπτύχθηκε με την επιρροή της προβλεπόμενης ανάπτυξης του μοντέλου. Αντί να γίνεται λεπτή ρύθμιση όλων των επιπέδων των Συνελκτικών Νευρωνικών Δικτύων (CNN), ρυθμίζεται μόνο το τελευταίο υποσύνολο επιπέδων. Αυτό εξοικονομεί χρόνο για τον προγραμματιστή και ελαχιστοποιεί τον αριθμό των τιμών ενημέρωσης βαρών που προκύπτουν από την ενημέρωση των προ-εκπαιδευμένων βαρών με κλίσεις ενός νέου συνόλου δεδομένων, περιορίζοντας έτσι τις μεγάλες αλλαγές στον αρχικό εξολκέα χαρακτηριστικών. Εάν ο εξολκέας χαρακτηριστικών παραμείνει σταθερός λόγω αυτής της περιορισμένης προσαρμογής των προ-εκπαιδευμένων βαρών, θα πρέπει να ακολουθήσει ότι το μοντέλο TensorFlow Lite θα λειτουργήσει παρόμοια με αυτό που αναπτύχθηκε κατά τη διάρκεια της κατασκευής του μοντέλου Keras. Επίσης, η αρχιτεκτονική του μοντέλου ConvNeXt-Tiny παραμένει η ίδια (δηλαδή δομικά αμετάβλητη) με το αρχικό μοντέλο ConvNeXt-Tiny, έτσι ώστε οι υπάρχουσες βελτιστοποιήσεις χαμηλού επιπέδου να επιταχύνουν τη διαδικασία συμπερασμού στην CPU και την NPU του κινητού.

Το τελευταίο σημείο που πρέπει να ληφθεί υπόψη κατά την εκπαίδευση είναι η χρήση της παρακολούθησης AUC, ευαισθησίας, ειδικότητας και ακρίβειας ως συνάρτηση για την παρακολούθηση καθ' όλη τη διάρκεια της εκπαίδευσης, η οποία θα παρέχει στους χρήστες ένα ευρύ φάσμα στατιστικών στοιχείων που μπορούν να συγκρίνουν όταν αποφασίζουν ποιο όριο και ποια ζώνη κινδύνου θέλουν να χρησιμοποιήσουν για την ανάπτυξη του μοντέλου. Γνωρίζοντας πώς συμπεριφέρεται το μοντέλο σε διαφορετικά σημεία λειτουργίας, μπορούμε να επιλέξουμε τις κατάλληλες ρυθμίσεις παραμέτρων που θα παραμείνουν έγκυρες όταν αντιμετωπίσουμε μια μικρή αλλαγή στην κατανομή, π.χ. εικόνες που έχουν ληφθεί από δερματοσκοπικές εικόνες στο σύνολο εκπαίδευσης και φωτογραφίες που έχουν ληφθεί υπό μη ρεαλιστικές συνθήκες (ακατάλληλος φωτισμός ή κακή εστίαση) από τους χρήστες. Επομένως, η αρχιτεκτονική/σχεδιασμός του μοντέλου και η στρατηγική εκπαίδευσης που

περιγράφονται δεν είναι απλώς θέμα βελτιστοποίησης του συνόλου επικύρωσης. Επιπλέον ενισχύουν την καταλληλότητα του μοντέλου για εφαρμογή σε περιβάλλον κινητής συσκευής.

4.8 Αρχιτεκτονικοί περιορισμοί και πιθανές μελλοντικές εργασίες

Η επιλεγμένη αρχιτεκτονική έχει αποδώσει ικανοποιητικά για τη δυαδική ταξινόμηση καλοήθων/κακοήθων βλαβών, έχει ορισμένους εγγενείς περιορισμούς που πρέπει να αναγνωριστούν. Ο πρώτος περιορισμός είναι ότι το μοντέλο δεν λαμβάνει υπόψη κλινικά μεταδεδομένα σχετικά με τον ασθενή, όπως την ηλικία, το φύλο ή τη θέση της βλάβης. Στην πράξη, αυτά τα κλινικά στοιχεία συχνά επηρεάζουν τη διάγνωση, οπότε η αρχιτεκτονική πρέπει να θεωρείται ως ένας εκτιμητής κινδύνου βάσει εικόνων που υποστηρίζει και συμπληρώνει την κλινική κρίση και παρέχει μια μερική εικόνα του συνολικού κινδύνου.

Ο δεύτερος περιορισμός της τρέχουσας αρχιτεκτονικής είναι ότι εκπαιδεύτηκε με δερματοσκοπικές φωτογραφίες από τη βάση δεδομένων HAM10000 και ενδέχεται να μην καταγράφει επαρκώς την ποικιλομορφία των τύπων δέρματος, των συσκευών απεικόνισης και των φωτογραφικών συνθηκών που υπάρχουν σε πραγματικές συνθήκες εκτός κλινικού περιβάλλοντος. Οι προγραμματιστές έκαναν εκτεταμένη χρήση της επαύξησης δεδομένων και της προσεκτικής προεπεξεργασίας για να ελαχιστοποιήσουν αυτό το κενό, αλλά η τρέχουσα αρχιτεκτονική δεν μοντελοποιεί ρητά την ετερογένεια που μπορεί να υπάρχει λόγω διαφορών στις συσκευές ή παραλλαγών στον τομέα. Μελλοντικές έρευνες μπορεί να διερευνήσουν τη χρήση τεχνικών προσαρμογής τομέα, την εκπαίδευση σε πολλαπλά σύνολα δεδομένων ή τη συμπερίληψη ρητών μπλοκ κανονικοποίησης για να ληφθούν υπόψη οι διαφορές στον φωτισμό και την ισορροπία χρωμάτων.

Ένας τρίτος αρχιτεκτονικός περιορισμός είναι ότι η τρέχουσα έξοδος είναι μια δυαδική ταξινόμηση, ενώ τα σύνολα δεδομένων περιλάμβαναν πολλαπλές κλινικές κατηγορίες. Η απόφαση να συγκεντρωθούν όλες οι κακοήθεις διαγνώσεις σε μία κατηγορία και όλες οι καλοήθεις διαγνώσεις στην άλλη κατηγορία μειώνει την πολυπλοκότητα του προβλήματος και ευθυγραμμίζεται με τον στόχο του προγραμματιστή να παράγει διαστρωμάτωση κινδύνου για βλάβες εντός μιας κινητής συσκευής. Ωστόσο, αυτό έχει ως αποτέλεσμα την απώλεια πληροφοριών σχετικά με τον συγκεκριμένο υποτύπο της βλάβης (καλοήθους ή του κακοήθους) που υπάρχει. Η βελτίωση της κεφαλής ταξινόμησης ώστε να επιτρέπει πολλαπλές εξόδους ή τη συμπερίληψη πρόσθετων βοηθητικών κεφαλών που θα μπορούσαν να προβλέψουν άλλα χαρακτηριστικά (έκταση κακοήθειας κ.λπ.) θα ήταν επωφελής τόσο για τους χρήστες όσο και για τους κλινικούς ιατρούς. Ωστόσο, θα πρέπει να δοθεί η δέουσα προσοχή σε πιθανές παρερμηνείες των λεπτομερών αποτελεσμάτων πρόβλεψης.

Τέλος, η υπάρχουσα αρχιτεκτονική αντιμετωπίζει το τρέχον δίκτυο ως ταξινομητή μαύρου κουτιού. Το επίκεντρο της διατριβής είναι η ποσοτική απόδοση της αρχιτεκτονικής και όχι οι μέθοδοι σχεδιασμού για ερμηνευσιμότητα. Η διάταξη του δικτύου ιδιαίτερα ο χάρτης χαρακτηριστικών που παράγεται ρητά από το ConvNeXt-Tiny και οι συντελεστές βαρύτητας προσοχής ανά κανάλι που εμφανίζονται στο μπλοκ SE υποδηλώνει ότι οι σχεδιαστές θα μπορούσαν να αναπτύξουν μεθόδους για τη δημιουργία οπτικών εξηγήσεων για τις προβλέψεις, όπως τεχνικές Class Activation Mapping (CAM). Οι εξηγήσεις θα παρέχουν κάποια εικόνα για το γιατί ορισμένες βλάβες έλαβαν μια συγκεκριμένη βαθμολογία κινδύνου, αλλά θα παρουσιάσουν επίσης νέα ερωτήματα σχετικά με τους παρόχους υγειονομικής περίθαλψης όσον αφορά την αξιοπιστία των εξηγήσεων που έλαβαν, το μέγεθος του γνωστικού φορτίου που θα προκύψει κατά την ερμηνεία και την ευπάθεια σε συνεχή υπερβολική αυτοπεποίθηση. Ο συγγραφέας ενθαρρύνει τους μελλοντικούς ερευνητές να συνεχίσουν να βασίζονται στην εκπαιδευτική διαδικασία και την αρχιτεκτονική που παρουσιάζονται σε αυτό το κεφάλαιο και να επιδιώξουν να απαντήσουν σε αυτά τα ερωτήματα.

4.9 Σύνοψη

Συνοψίζοντας, αυτό το κεφάλαιο παρουσίασε την αρχιτεκτονική και την προσέγγιση εκπαίδευσης του ταξινομητή καλοήθους ή κακοήθους στο κέντρο του συστήματος. Το μοντέλο αποτελείται από ένα ConvNeXt-Tiny backbone με ένα μπλοκ squeeze-and-excitation channel-attention, μαζί με ένα συμπαγές κεφάλι ταξινόμησης που παράγει πιθανότητες κακοήθειας. Το μοντέλο εκπαιδεύεται σε δύο στάδια και χρησιμοποιεί δυαδική απώλεια διασταυρούμενης εντροπίας με στάθμιση κλάσης, ενώ ενσωματώνει ένα ισχυρό σχέδιο επαύξησης δεδομένων και μηχανισμό πρόωρης διακοπής για τη βελτίωση της απόδοσης επικύρωσης. Η έξοδος του εκπαιδευμένου μοντέλου, που αποθηκεύεται σε μορφή Keras, χρησιμοποιείται ως βάση για τη μετατροπή TensorFlow Lite, την αξιολόγηση, την επιλογή κατωφλίου και, τελικά, την παρουσίαση στο επόμενο κεφάλαιο.

Συμπερασματικά, το κεφάλαιο αυτό παρέχει μια αναλυτική εικόνα της πλήρους αρχιτεκτονικής και της μεθοδολογίας εκπαίδευσης του ταξινομητή καλοήθων-κακοήθων, ο οποίος αποτελεί το κεντρικό στοιχείο αυτού του συστήματος. Ενσωμάτωσε την αρχιτεκτονική ενός ConvNeXt-Tiny backbone που προ-εκπαιδεύτηκε στο ImageNet με ένα ελαφρύ μπλοκ Squeeze-and-Excitation και μια συμπαγή, πυκνή κεφαλή ταξινόμησης. Ο συνδυασμός αυτών των τριών βασικών στοιχείων επιτρέπει τη μετατροπή μιας περικομμένης δερματοσκοπικής εικόνας 256x256 σε μια ενιαία πιθανότητα εξόδου για κακοήθη δυναμικό, διατηρώντας παράλληλα τη δέουσα προσοχή στα συνολικά δομικά χαρακτηριστικά και τη σημασία κάθε χαρακτηριστικού ανά κανάλι.

Εκτός από την περιγραφή της ίδιας της αρχιτεκτονικής, αυτό το κεφάλαιο δίνει επίσης έμφαση στο σχεδιασμό του προγράμματος εκπαίδευσης. Η ανισορροπία των κλάσεων αντιμετωπίστηκε μέσω της υπερδειγματοληψίας, δημιουργώντας το μοντέλο με συναρτήσεις στάθμισης κλάσεων και δυαδική διασταυρούμενη εντροπία, ενώ ο σχεδιασμός του βελτιστοποιητή είχε ως στόχο να εξασφαλίσει την ισορροπία μεταξύ σταθερότητας και ταχύτητας στο μοντέλο. Έχει επίσης σχεδιαστεί με ένα πρόγραμμα δύο φάσεων, έτσι ώστε η εκπαίδευση να μπορεί να επωφεληθεί από τη μεταφορά μάθησης, ενώ παράλληλα συνεχίζει να αναπτύσσεται το μοντέλο για να προσαρμοστεί στα μοναδικά χαρακτηριστικά της δερματοσκοπικής απεικόνισης. Μέσω του μηχανισμού πρόωρης διακοπής διπλού στόχου, αυτό το μοντέλο θα μπορούσε να επιλεγεί όχι μόνο για γενικές δυνατότητες διάκρισης μεταξύ των αντίστοιχων συμμετριών τους, αλλά και ειδικά για την ανίχνευση κακοήθων βλαβών.

Αυτά τα χαρακτηριστικά σχεδιασμού υπερβαίνουν τις τεχνικές λεπτομέρειες της μεθοδολογίας και επηρεάζουν τα στάδια αξιολόγησης και ανάπτυξης του ταξινομητή. Ανάλογα με τον τρόπο εκπαίδευσης του μοντέλου, καθορίζονται τα εφικτά εύρη ευαισθησίας/ειδικότητας όταν μεταβάλλεται το όριο απόφασης του μοντέλου κατά την αξιολόγηση στο σύνολο δεδομένων επικύρωσης. Ο τρόπος δομής του τελικού πυκνού στρώματος του μοντέλου επιτρέπει την εύκολη αντιστοίχιση των πιθανοτήτων στο πυκνό στρώμα εξόδου με τις κατανοητές κατηγορίες κινδύνου/μηνύματα σοβαρότητας της εφαρμογής για κινητά που βλέπει ο χρήστης. Τα κεφάλαια 5 και 6 επεκτείνουν περαιτέρω αυτή τη βάση και εξετάζουν την κλινική αξιολόγηση του μοντέλου μαζί με την επιλογή κλινικά σημαντικών ορίων, καθώς και τον τρόπο ενσωμάτωσης του εκπαιδευμένου μοντέλου σε μια ροή εργασίας smartphone, έτσι ώστε οι τελικοί χρήστες να μπορούν να έχουν εύκολη πρόσβαση και να το χρησιμοποιούν στις δικές τους κλινικές ροές εργασίας.

Κεφάλαιο 5ο: Αξιολόγηση και επιλογή κατωφλίου

Σε αυτή την ενότητα εξηγείται πώς να αξιολογείται το εκπαιδευμένο μοντέλο και πώς επιλέγονται οι αποφάσεις κατωφλίου και οι ζώνες κινδύνου που θα χρησιμοποιηθούν στην εφαρμογή για κινητά. Η έμφαση δίνεται στη διαδικασία και όχι σε συγκεκριμένα αριθμητικά αποτελέσματα (τα οποία προέρχονται από την τελική εκπαίδευση και μπορούν να εμφανιστούν σε πίνακες και σχήματα στο έγγραφο της διατριβής). Η αξιολόγηση πραγματοποιείται πρώτα με το μοντέλο Keras και ένα μοντέλο TensorFlow Lite που προκύπτει από τη μετατροπή του αντίστοιχου μοντέλου Keras σε TensorFlow. Εκτός από τις αξιολογήσεις, πραγματοποιούνται συστηματικές αναζητήσεις κατωφλίων για τον προσδιορισμό των σημείων λειτουργίας και των ζωνών χαμηλού, μέτριου και υψηλού κινδύνου, ώστε να αντικατοπτρίζεται μια προσέγγιση σχεδιασμού που δίνει προτεραιότητα στην ασφάλεια.

5.1 Ρύθμιση αξιολόγησης

Όλες οι αξιολογήσεις σε αυτήν την ενότητα πραγματοποιούνται χρησιμοποιώντας το υποσύνολο επικύρωσης του συνόλου δεδομένων HAM10000 που ορίζεται στο Κεφάλαιο 3. Κάθε αξιολόγηση χρησιμοποιεί τις ίδιες εικόνες, δυαδικές ετικέτες και αλυσίδα προεπεξεργασίας. Αυτός αποτελείται από την κεντρική περικοπή κάθε εικόνας σε τετράγωνο, την αλλαγή του μεγέθους σε 256 x 256 pixels και τη μετατροπή των εικόνων σε πίνακα RGB τύπου float32. Οι εικόνες τροφοδοτούνται απευθείας στο μοντέλο Keras, το οποίο αυτοματοποιεί την εσωτερική προεπεξεργασία ConvNeXt πριν επιστρέψει πιθανότητες κακοήθειας μεταξύ 0-1. Για το μοντέλο TensorFlow Lite, οι εικόνες μεταβιβάζονται σε έναν διερμηνέα TFLite, ο οποίος μπορεί στη συνέχεια να επιστρέψει μια πιθανότητα κακοήθειας από τον πίνακα εξόδου. Οι κύριες μετρήσεις για τον ορισμό της απόδοσης είναι η ευαισθησία, η ειδικότητα, η ακρίβεια και η περιοχή κάτω από την καμπύλη χαρακτηριστικών λειτουργίας του δέκτη. Αυτές οι μετρικές χρησιμοποιούνται κατά κόρον για την αξιολόγηση διαγνωστικών εξετάσεων, καθώς αποτυπώνουν την ικανότητα ενός μοντέλου να ξεχωρίζει ανάμεσα σε θετικές και αρνητικές περιπτώσεις [18]. Η ευαισθησία μετρά το ποσοστό των κακοήθων βλαβών που χαρακτηρίζονται κακοήθεις σε ένα συγκεκριμένο όριο απόφασης, ενώ η ειδικότητα μετρά το ποσοστό των καλοήθων βλαβών που χαρακτηρίζονται καλοήθεις. Η ακρίβεια μετρά το συνολικό ποσοστό των σωστών προβλέψεων. Τέλος, οι πίνακες σύγχυσης χρησιμοποιούνται για να απεικονίσουν τον τρόπο με τον οποίο οι καλοήθεις και οι κακοήθεις περιπτώσεις επισημαίνονται στις προβλεπόμενες κατηγορίες σε συγκεκριμένα κατώφλια.

Σε αυτή την περίπτωση, ο σχεδιασμός της διαδικασίας αξιολόγησης έχει οδηγήσει σε έμφαση στο μοντέλο που αξιολογείται (M) σε αντίθεση με τον αγωγό προεπεξεργασίας δεδομένων. Τα δεδομένα εικόνας (και οι δυαδικές ετικέτες) για όλα τα σύνολα αξιολόγησης θα συνεχίσουν να χρησιμοποιούν την ίδια λίστα διαδρομών αρχείων εικόνας και τη λίστα δυαδικών ετικετών που δημιουργήθηκαν στην Ενότητα 3 για χρήση στις διαχωρισμένες επικυρωμένες πληροφορίες. Κάθε μία από τις εικόνες υποβάλλεται μέσω των ίδιων διαδικασιών προεπεξεργασίας με αυτές που πραγματοποιήθηκαν για την εκπαίδευση κάθε μοντέλου, συμπεριλαμβανομένων: της τετραγωνικής κεντροθέτησης (C) της εικόνας εισόδου, της αλλαγής μεγέθους της εικόνας εισόδου σε 256 x 256 pixel και της μετατροπής της εικόνας σε πίνακα RGB τριών καναλιών με κινητή υποδιαστολή. Κατά την αξιολόγηση του μοντέλου Keras, οι προεπεξεργασμένοι πίνακες μεταβιβάζονται στο μοντέλο ConvNeXt-Tiny με το όρισμα `include_preprocessing=True`, το οποίο εντός του μοντέλου μετατρέπει τις προεπεξεργασμένες εικόνες σε κανονικοποιημένες (έτοιμες για ImageNet) πριν από τη βαθμολόγηση (παράγοντας βαθμολογίες πιθανότητας κακοήθειας στην περιοχή [0, 1]).

Οι ίδιες προεπεξεργασμένες εικόνες θα σταλούν στη συνέχεια στον διερμηνέα TFLite και θα χρησιμοποιηθούν για τη δημιουργία τανυστών εισόδου και εξόδου, την αντιγραφή των αντίστοιχων εικόνων στον αντίστοιχο buffer εισόδου και την αποστολή των προεπεξεργασμένων εικόνων. Από τον τανυστή εξόδου του διερμηνέα TFLite, θα ανακτηθεί μια μοναδική σκαλαρική πιθανότητα κακοήθειας για καθεμία από τις εικόνες του συνόλου επικύρωσης. Η στενή αντιστοιχία μεταξύ των ευρημάτων της αξιολόγησης Keras και της διαδρομής αξιολόγησης TFLite επιτρέπει μια σαφώς καθαρή αξιολόγηση των διαφορών στην απόδοση μεταξύ του M και εκείνων που βασίζονται αποκλειστικά στην εισαγωγή δεδομένων και την αριθμητική ακρίβεια.

Επιπλέον, οι μετρήσεις για όλες τις αξιολογημένες εικόνες θα υπολογιστούν στο σύνολο επικύρωσης, συμπεριλαμβανομένων εικόνων από διάφορα επίπεδα δυσκολίας (οι περισσότερες «εύκολες» εικόνες) και δεν θα εξαιρούν εικόνες που είναι δύσκολο να αξιολογηθούν. Αυτή η απόφαση επιτρέπει ρεαλιστικά σενάρια δοκιμών, επειδή η εφαρμογή για κινητά δεν έχει προηγούμενη γνώση των «δύσκολων» εικόνων. Επομένως, πρέπει να είναι σε θέση να αξιολογείται χρησιμοποιώντας εικόνες από σαφή, οριακά και θορυβώδη επίπεδα που αναμένεται να χρησιμοποιούν οι τελικοί χρήστες.

5.2 Απόδοση επικύρωσης του μοντέλου Keras

Μετά την εκπαίδευση, το μοντέλο Keras που έχει την καλύτερη απόδοση με βάση τον αλγόριθμο πρόωρης διακοπής που περιγράφεται στο κεφάλαιο 4 έχει δοκιμαστεί σε ολόκληρο το σύνολο δεδομένων επικύρωσης. Για κάθε εικόνα στο σύνολο δεδομένων επικύρωσης, το μοντέλο παράγει πιθανότητα κακοήθειας. Αυτές οι πιθανότητες συγκεντρώνονται σε έναν πίνακα με την αντίστοιχη ετικέτα πραγματικής κατάστασης, καλοήθη ή κακοήθη.

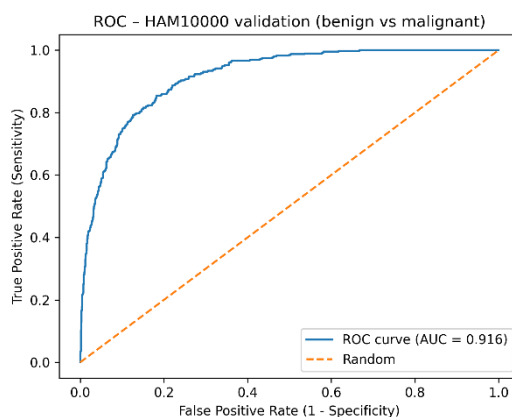
Για να συσχετιστούν αυτές οι πιθανότητες με τις πραγματικές αποφάσεις, θα οριστούν συγκεκριμένα κατώφλια ανάλογα με την ευαισθησία του αρχείου keras. Τα συστήματα πρόβλεψης κινδύνου στην ιατρική αξιολογούνται συχνά με βάση την ακρίβεια των προβλέψεών τους, δηλαδή το πόσο καλά οι προβλεπόμενες πιθανότητες συμφωνούν με τα πραγματικά ποσοστά εμφάνισης ενός γεγονότος. Στον τομέα της ιατρικής αξιολογούνται συχνά αναφορικά με τη βαθμονόμηση των πιθανοτήτων τους. Αυτό σημαίνει ότι εξετάζεται κατά πόσο οι προγνωστικές πιθανότητες αντανακλούν τα πραγματικά ποσοστά εμφάνισης ενός συμβάντος [27]. Για παράδειγμα, ένα προεπιλεγμένο κατώφλι 0,5 καθώς και ένα εναλλακτικό κατώφλι που μεγιστοποιεί την ευαισθησία. Για κάθε κατώφλι ενδιαφέροντος, η προβλεπόμενη ετικέτα κλάσης προκύπτει από τη σύγκριση των προβλεπόμενων πιθανοτήτων με το καθορισμένο threshold, το οποίο στη συνέχεια επιτρέπει την παραγωγή ενός πίνακα. Μοντελοποιώντας όλες τις πιθανές τιμές των κατωφλίων, μπορεί το TensorFlow Lite να υπολογίσει τις αντίστοιχες τιμές ευαισθησίας, ειδικότητας και ακρίβειας. Στη συνέχεια, το κείμενο της διατριβής μπορεί να επισημάνει εάν το μοντέλο ταξινόμησης επιτυγχάνει το επίπεδο ευαισθησίας που θεωρείται αποδεκτό για κακοήθεις βλάβες και να εξετάσει πόση ειδικότητα θυσιάστηκε για να επιτευχθεί το επιθυμητό επίπεδο ευαισθησίας.

Υπάρχουν πολλοί λόγοι για την επικύρωση ενός μοντέλου Keras. Εκτός από την παροχή των αρχικών μετρήσεων αξιολόγησης που σχετίζονται με το AUC, την ευαισθησία, την ειδικότητα και την ακρίβεια (όλα ρυθμισμένα σε ένα προεπιλεγμένο όριο 0,5), παρέχει επίσης μια συνοπτική επισκόπηση της ικανότητας του δικτύου να διαφοροποιεί μεταξύ κακοήθων και καλοήθων βλαβών και αν τείνει περισσότερο προς την ευαισθησία έναντι της ειδικότητας ή το αντίστροφο. Επιπλέον, όταν εξετάζετε ολόκληρη την καμπύλη ROC, μπορείτε να δείτε πώς αλλάζουν αυτές οι δύο μετρήσεις (ευαισθησία και ειδικότητα) καθώς το όριο απόφασης μετακινείται από 0 (το σημείο μέγιστης ευαισθησίας) σε 1. Ένα

μοντέλο με μεγαλύτερο AUC επιτρέπει στον χρήστη να βρει ένα αποδεκτό όριο με υψηλή ευαισθησία και ικανοποιητική ειδικότητα.

Η αξιολόγηση Keras επιτρέπει επίσης στους χρήστες να κατασκευάζουν πίνακες σύγκρισης που δείχνουν τόσο θετικές όσο και αρνητικές αξιολογήσεις της εικόνας ή των εικόνων, ανεξάρτητα από το επίπεδο κατωφλίου που έχει επιλέξει ο χρήστης, για παράδειγμα αληθινά θετικά/αληθινά αρνητικά/ψευδώς θετικά/ψευδώς αρνητικά για ένα δεδομένο επίπεδο ή επίπεδα κατωφλίου. Ενώ τα αποτελέσματα της κατασκευής πινάκων σύγκρισης μπορούν να αναφερθούν λεπτομερώς, είναι επίσης δυνατό να σχολιαστούν γενικές κατηγορίες σφαλμάτων, όπως η τάση των περισσότερων σφαλμάτων να είναι ψευδώς θετικά. Για μια εφαρμογή με υψηλές συνέπειες (π.χ. έλεγχος μελανώματος), μπορεί να είναι αποδεκτή μια μικρή αύξηση των ψευδών θετικών, αρκεί το αποτέλεσμα να είναι μια μεγάλη μείωση των παραβλεφθέντων κακοηθών νεοπλασμάτων. Ένας πίνακας σύγκρισης παρέχει απτά παραδείγματα για το πώς συμβαίνουν αυτές οι συμβιβαστικές λύσεις.

Εκτός από την παροχή μιας αξιολόγησης του μοντέλου με ένα μόνο όριο, είναι επίσης σημαντικό να ληφθούν υπόψη οι προβλεπόμενες πιθανότητες του μοντέλου στο σύνολο δεδομένων επικύρωσης. Τα ιστογράμματα των προβλεπόμενων πιθανοτήτων για καλοήθεις έναντι κακοήθων βλαβών θα δείξουν εάν ο ταξινομητής έχει την τάση να παράγει είτε με βεβαιότητα διαχωρισμένα αποτελέσματα πολύ υψηλών και πολύ χαμηλών τιμών είτε την τυπική ομαδοποίηση βαθμολογιών κοντά στο 0,5. Ένα καλά βαθμονομημένο μοντέλο θα αποδώσει υψηλή πιθανότητα σε πραγματικές κακοήθεις βλάβες και χαμηλή πιθανότητα σε σαφώς καλοήθεις βλάβες, με τις οριακές περιπτώσεις να βρίσκονται στο μεσαίο εύρος της κατανομής στο ιστόγραμμα. Επομένως, παρόλο που η κατασκευή λεπτομερών διαγραμμάτων βαθμονόμησης δεν είναι απαραίτητη για την παρούσα διατριβή, οι έννοιες που υποκειμέθα στη βαθμονόμηση ενός μοντέλου θα βοηθήσουν στην επιλογή των οριακών τιμών και των ζωνών κινδύνου αργότερα στη διατριβή. Δηλαδή, όσο μεγαλύτερος είναι ο διαχωρισμός των κατανομών πιθανότητας καλοήθους και κακοήθους, τόσο ευκολότερο θα είναι να προσδιοριστεί μια περιοχή χαμηλού κινδύνου με μικρό ποσοστό κακοηθειών.



Σχήμα 5.1: Καμπύλη ROC στο σύνολο επικύρωσης HAM10000

5.3 Συνεκτικότητα μεταξύ μοντέλων Keras και μοντέλων TensorFlow Lite

Αφού αξιολογηθεί και κατασκευαστεί το μοντέλο Keras, το μοντέλο μπορεί να μετατραπεί σε TensorFlow Lite και, στη συνέχεια, το μοντέλο TFLite να αξιολογηθεί στις εικόνες επικύρωσης. Ο σκοπός αυτού είναι να αξιολογηθεί εάν η μετατροπή και οι τυχόν επακόλουθες βελτιστοποιήσεις επηρεάζουν την απόδοση και τη συμπεριφορά του μοντέλου. Η διαδικασία αξιολόγησης θα είναι

παρόμοια με την επικύρωση στο μοντέλο: κάθε προ-επεξεργασμένη εικόνα επικύρωσης υποβάλλεται στον διερμηνέα TFLite, καταγράφεται η πιθανότητα εξόδου και υπολογίζετε τις ίδιες μετρήσεις με τον ίδιο τρόπο.

Στην πράξη, θα περιμέναμε διαφορές της τάξης του $1e-3$ έως $1e-6$ στις τιμές πιθανότητας μεταξύ των αποτελεσμάτων του Keras και του TensorFlow Lite, απλώς λόγω διαφορών στην υλοποίηση και πιθανώς μειωμένης ακρίβειας στο μοντέλο TFLite.

Η επιλογή του ορίου και ο σχεδιασμός της ζώνης κινδύνου βασίζονται στη συμπεριφορά του μοντέλου TFLite που εκτελείται σε μια συσκευή χρήστη. Εάν υπάρχουν σημαντικές ασυνέπειες μεταξύ των δύο εκδόσεων, τότε οι μετρήσεις επικύρωσης που υπολογίζονται στο στάδιο Keras δεν θα αντιπροσωπεύουν σωστά την απόδοση των μοντέλων σε πραγματικές περιπτώσεις χρήσης. Για να εξασφαλιστεί η ακρίβεια κατά την αξιολόγηση, και τα δύο μοντέλα αξιολογούνται χρησιμοποιώντας τις ίδιες εικόνες επικύρωσης, και η πιθανότητα κακοήθειας για κάθε δείγμα καταγράφεται πριν από τον υπολογισμό των διαφορών (ζεύγη) στις πιθανότητες. Σε μια σωστά λειτουργούσα διαδικασία μετατροπής, οι διαφορές μεταξύ των δύο εκδόσεων θα πρέπει να είναι πολύ μικρές.

Επομένως, η ανάλυση παρέχει τόσο τη μέση απόλυτη διαφορά πιθανότητας όσο και τον αριθμό των δειγμάτων που θα αλλάξουν από κακοήθη σε καλοήθη (ή αντίστροφα) όταν υπολογίζονται με το ίδιο κατώφλι χρησιμοποιώντας Keras και TFLite. Στην ιδανική περίπτωση, αυτό το ποσοστό διαφορετικών ταξινομήσεων θα πρέπει να είναι πολύ κοντά στο μηδέν, καθώς ακόμη και μικρές διαφορές θα πρέπει να έχουν ελάχιστη ή καμία επίδραση στη χρήση των μοντέλων.

Ο έλεγχος συνέπειας βοηθά επίσης να διασφαλιστεί ότι, καθώς πραγματοποιούνται τα επόμενα βήματα (δηλ. αναζήτηση μέσω των ορίων TFLite και δημιουργία ζωνών κινδύνου), οι υπολογισμοί βασίζονται στη συμπεριφορά του σωστού μοντέλου και ότι τα σφάλματα ή τα τεχνητά στοιχεία από τη διαδικασία μετατροπής λαμβάνονται υπόψη κατά την επιλογή των ορίων. Αυτό το κεφάλαιο θα δείξει τη σχέση μεταξύ της συμπεριφοράς του μοντέλου κατά την εκπαίδευση και της απόδοσης του τελικού μοντέλου έτοιμου για παραγωγή.

5.4 Αναζήτηση κατωφλίου στις εξόδους του TensorFlow Lite

Δεδομένου ότι η εφαρμογή για κινητά τελικά χρησιμοποιεί το μοντέλο TensorFlow Lite, η λεπτομερής ανάλυση των κατωφλίων πραγματοποιείται στις εξόδους του TFLite. Το σενάριο φορτώνει το μοντέλο TFLite, το εκτελεί σε όλες τις εικόνες επικύρωσης και αποθηκεύει τις προκύπτουσες πιθανότητες κακοήθειας με την ετικέτα ground-truth.

Για κάθε υποψήφιο όριο, υπολογίζει την ευαισθησία, την ειδικότητα και την ακρίβεια. Επιπλέον, υπολογίζεται ένας συνοπτικός δείκτης, ο δείκτης Youden, ο οποίος ισούται με το άθροισμα της ευαισθησίας και της ειδικότητας μείον ένα. Τα κατώφλια που μεγιστοποιούν τον δείκτη Youden αντιστοιχούν σε σημεία της καμπύλης ROC που έχουν σχετικά καλή ισορροπία ευαισθησίας και ειδικότητας. Ο δείκτης Youden αποτελεί μια κλασική στατιστική παράμετρο για την επιλογή του κατωφλίου σε διαγνωστικά τεστ, καθώς έχει στόχο τη μέγιστη ταυτόχρονη ευαισθησία και ειδικότητα [19]. Ταυτόχρονα, μπορούν επίσης να προσδιοριστούν κατώφλια που μπορούν να κατηγοριοποιηθούν ως αποδεκτά από έναν ελάχιστο περιορισμό ευαισθησίας. Η σύγκριση των κατωφλίων με εκείνα που ικανοποιούν έναν ελάχιστο περιορισμό ευαισθησίας αναδεικνύει τους συμβιβασμούς μεταξύ ισορροπίας, απόδοσης και συντηρητικής επιλογής υπέρ της ευαισθησίας.

Για κάθε ένα από τα υποψήφια κατώφλια (t) σε αυτή στη διαδικασία αναζήτησης (ένα πυκνό πλέγμα μεταξύ μηδέν και ένα), το σενάριο μετατρέπει την προβλεπόμενη πιθανότητα σε δυαδική (δηλ. θετική ή αρνητική) πρόβλεψη, ενημερώνει τον αριθμό των καταγεγραμμένων αληθών θετικών, ψευδών θετικών, αληθών αρνητικών και ψευδών αρνητικών που προσδιορίζονται από το μοντέλο (σε σύγκριση με το σύνολο δεδομένων επικύρωσης) και δημιουργεί ένα σύνολο περιγραφικών στατιστικών που

περιλαμβάνει τα εξής: ευαισθησία, ειδικότητα, ακρίβεια και J (δείκτης Youden, που είναι η ευαισθησία + ειδικότητα -1).

Εκτελώντας ολόκληρο το πυκνό πλέγμα, τη στήλη i (που αντιπροσωπεύει ένα υποψήφιο όριο) κατά τη στήλη j (που υποδεικνύει ένα μέτρο) της καταγραφής δεδομένων, τα μέτρα μπορούν να αναλυθούν για τον προσδιορισμό των ορίων που επιτυγχάνουν το μέγιστο (α) του στατιστικού J και (β) ενός αυστηρού περιορισμού που θέτει ανώτατο ορόι στο ποσοστό των συνολικών κακοήθων βλαβών που προσδιορίζονται στο σύνολο δεδομένων επικύρωσης και τοποθετούνται στην τελική περιοχή χαμηλού κινδύνου. Μεταξύ αυτών των ορίων, μπορεί στη συνέχεια να διεξαχθεί ανάλυση για τον προσδιορισμό του ορίου που επιτρέπει τον μέγιστο αριθμό καλοήθων βλαβών να τοποθετηθούν στην κατηγορία χαμηλού κινδύνου, ώστε να μεγιστοποιηθεί η δυνατότητα διαβεβαίωσης χωρίς να δημιουργηθούν προβλήματα ασφάλειας για τους χρήστες.

Ο πίνακας ορίων και μετρήσεων που δημιουργείται με αυτή τη διαδικασία μπορεί επίσης να προσφέρει ευκαιρίες για την εξερεύνηση σεναρίων «τι θα συμβεί αν». Για παράδειγμα, το κείμενο εξετάζει πώς μια ελαφρώς υψηλότερη ειδικότητα μπορεί να εκτιμηθεί περισσότερο, με αποτέλεσμα χαμηλότερη ευαισθησία, ώστε να παρέχει ένα πιο συντηρητικό σημείο λειτουργίας με ειδικότητα. Η εξοικείωση των ομάδων ανάπτυξης και λειτουργίας με αυτά τα σενάρια βοηθά στην κατανόηση ότι τα τελικά λειτουργικά όρια που επιλέγονται για τις εφαρμογές κινητών συσκευών θα είναι το αποτέλεσμα λογικών συμβιβασμών μεταξύ του κόστους των ψευδώς θετικών ειδοποιήσεων και της απώλειας ανίχνευσης κακοήθων βλαβών.

5.5 Ορισμός ζωνών χαμηλού, μεσαίου και υψηλού κινδύνου

Η εφαρμογή δεν παρέχει κατώφλια ή ακατέργαστες πιθανότητες για κάθε άτομο. Αντίθετα, συνδυάζει τα αποτελέσματα του μοντέλου σε κατηγορίες ποιοτικού κινδύνου. Παρόμοιες μέθοδοι κατηγοριοποίησης των συνεχών πιθανοτήτων σε περιοχές κινδύνου έχουν εφαρμοστεί εκτενώς σε κλινικά προγνωστικά μοντέλα, με σκοπό την υποστήριξη της διαδικασίας λήψης αποφάσεων βάσει προκαθορισμένων ορίων [21]. Για τον ορισμό των κατηγοριών χαμηλού, μέσου και υψηλού κινδύνου, εκτελείται μια δεύτερη ανάλυση για τον εντοπισμό κατάλληλων χαμηλών και υψηλών κατωφλίων μέσα στις πιθανότητες εξόδου του TFLite, ώστε να χωρίζεται η πιθανότητα σε τρεις ζώνες.


Στην ανάλυση, το υψηλό όριο θα επιλέγεται γενικά πρώτα με βάση περιορισμούς προσδιορίζοντας ένα σημαντικό ποσοστό κακοήθων βλαβών που εντοπίζονται σε αυτή τη ζώνη υψηλού κινδύνου. Όταν επιλέγεται ένα υποψήφιο υψηλό όριο, θα συνεχίσει να αναζητά ένα χαμηλό όριο που ικανοποιεί έναν περιορισμό ασφάλειας στη ζώνη χαμηλού κινδύνου, έτσι ώστε το χαμηλό όριο να είναι αρκετά μικρό ώστε μόνο ένα περιορισμένο ποσοστό κακοήθων βλαβών να εντοπίζεται στη ζώνη χαμηλού κινδύνου. Για παράδειγμα, το κατώφλι μπορεί να οριστεί έτσι ώστε να μην ανατεθεί στη ζώνη χαμηλού κινδύνου περισσότερο από ένα προκαθορισμένο ποσοστό κακοήθων περιπτώσεων στο σύνολο επικύρωσης. Από τα διάφορα κατώφλια που είναι διαθέσιμα για την κάλυψη των απαιτήσεων, «Το τελικό κατώφλι επιλέγεται βάσει της καλύτερης συνολικής ισορροπίας μεταξύ του μεγέθους και της καθαρότητας των ζωνών χαμηλού και μεσαίου κινδύνου.

(η στήλη TLOW είναι το κατώτατο όριο – TLOW και η στήλη THIGH είναι το ανώτατο όριο – THIGH), έτσι ώστε η πιθανότητα να χωριστεί σε τρεις (3) ζώνες κινδύνου. Η ζώνη χαμηλού κινδύνου αποτελείται από όλες τις πιθανότητες που είναι μικρότερες ή ίσες με το TLOW. Η ζώνη μέσου κινδύνου αποτελείται από όλες τις πιθανότητες που εμπίπτουν στο εύρος TLOW και THIGH. Η ζώνη υψηλού κινδύνου αποτελείται από όλες τις πιθανότητες που είναι μεγαλύτερες ή ίσες με THIGH. Για καθεμία από τις τρεις (3) ζώνες κινδύνου, η ανάλυση επικύρωσης περιλαμβάνει τόσο τον αριθμό των βλαβών που περιλαμβάνονται σε καθεμία από αυτές τις ζώνες κινδύνου όσο και τον αριθμό των βλαβών που είναι πραγματικά κακοήθεις. Αυτές οι μετρήσεις παρέχουν μια διαισθητική, κλινικά σχετική σύνοψη αυτών των αποτελεσμάτων. Για παράδειγμα, η σύνοψη παρέχει τον αριθμό των καλοήθων βλαβών που θα είχαν ταξινομηθεί ως υψηλού κινδύνου (πιθανότητα υπερβολικών παραπομπών), καθώς και τον αριθμό

των κακοήθων βλαβών που θα είχαν ταξινομηθεί ως χαμηλού κινδύνου (πιθανώς επικίνδυνες παραλείψεις).

Η επιλογή TLOW βασίζεται κυρίως σε κριτήρια ασφάλειας. Ο στόχος του σχεδιασμού είναι ότι ουσιαστικά καμία (ιδανικά μηδέν) από τις κακοήθεις βλάβες που υπάρχουν στα δεδομένα επικύρωσης δεν πρέπει να περιλαμβάνεται στη ζώνη χαμηλού κινδύνου. Αυτό χρησιμεύει για να διασφαλιστεί ότι οι ασθενείς που λαμβάνουν αποτέλεσμα χαμηλού κινδύνου με βάση την κατανομή δεδομένων που αντιπροσωπεύεται από το HAM10000 είναι ουσιαστικά βέβαιοι ότι δεν έχουν κακοήθη βλάβη. Έτσι, η ζώνη ενδιάμεσου κινδύνου θα καταγράψει τις πιο ασαφείς περιπτώσεις όπου το μοντέλο δεν παρέχει ισχυρές ενδείξεις υπέρ ή κατά της κακοήθειας.

Πρέπει να σημειωθεί ότι οι ετικέτες χαμηλού κινδύνου, ενδιάμεσου κινδύνου και υψηλού κινδύνου που χρησιμοποιούνται στην εφαρμογή για κινητά δεν είναι ιατρικές διαγνώσεις, αλλά δομημένες περιλήψεις των αποτελεσμάτων του μοντέλου. Τα κειμενικά μηνύματα που σχετίζονται με κάθε Ζώνη Κινδύνου (τα οποία θα συζητηθούν στο Κεφάλαιο 6) προωθούν τη συντηρητική συμπεριφορά: τα αποτελέσματα Υψηλού και Ενδιάμεσου Κινδύνου συνιστούν ιατρική αξιολόγηση, ενώ τα αποτελέσματα Χαμηλού Κινδύνου υπενθυμίζουν στους χρήστες να παρακολουθούν το δέρμα τους και να επικοινωνούν με έναν ιατρό εάν παρατηρήσουν αλλαγές. Το παρόν κεφάλαιο παρέχει μια σύνδεση μεταξύ της Μαθηματικής Διαδικασίας Επιλογής για τα Όρια και της πραγματικής Επικοινωνίας Κινδύνου από την προοπτική των χρηστών μέσω της Ποσοτικής Ανάλυσης της Απόδοσης Επικύρωσης.



Σχήμα 5.2: Σχηματική απεικόνιση ζωνών

5.6 Ανάλυση σφαλμάτων

Εκτός από τα συνολικά μέτρα και τα όρια, είναι επίσης χρήσιμο να εξετάζονται τα μεμονωμένα σφάλματα που κάνει το μοντέλο. Συγκεκριμένα, τα ψευδώς αρνητικά αποτελέσματα στη ζώνη χαμηλού κινδύνου είναι τα σφάλματα που προκαλούν τη μεγαλύτερη ανησυχία, καθώς πρόκειται για κακοήθεις βλάβες που το σύστημα υποδηλώνει ότι είναι σχετικά ακίνδυνες καλοήθεις βλάβες. Εξετάζοντας δείγματα ψευδών αρνητικών, μπορεί κανείς να αναζητήσει μοτίβα ή δείκτες ποιοτικής μελέτης, όπως ασυνήθιστες μορφολογίες, άτυπα χρώματα ή φαινόμενα απόκρυψης από τρίχες και σκιές. Ορισμένες τέτοιες ποιοτικές έρευνες συλλέγουν πληροφορίες σχετικά με τα όρια των δεδομένων εκπαίδευσης ή τη στρατηγική αύξησης των δεδομένων σχετικά με το περιθώριο βελτίωσης της απόδοσης του μοντέλου.

Τα ψευδώς θετικά αποτελέσματα μπορεί επίσης να απαιτούν κάποια προσοχή, ειδικά σε σχέση με περιπτώσεις στην ζώνη υψηλού κινδύνου που θα ήταν καλοήθεις βλάβες που το μοντέλο ταξινόμησε ως υψηλού κινδύνου. Αυτές οι περιπτώσεις είναι σημαντικές καθώς μπορεί να προκαλέσει περιττή ανησυχία στους χρήστες και αυξημένες ιατρικές παραπομπές.

Αν και οι ποσοτικές μετρήσεις και οι πίνακες ορίων είναι ζωτικής σημασίας, από μόνες τους δεν παρέχουν μια σε βάθος κατανόηση των λόγων για τους οποίους το μοντέλο κάνει λανθασμένες ταξινομήσεις. Επομένως, η ποιοτική ανάλυση σφαλμάτων θα επικεντρωθεί σε αντιπροσωπευτικά παραδείγματα λανθασμένων ταξινομήσεων σε κάθε ζώνη κινδύνου. Για παράδειγμα, τα ψευδώς αρνητικά αποτελέσματα στη ζώνη χαμηλού κινδύνου μπορούν να χαρακτηριστούν ως κακοήθεις βλάβες που έχουν ταξινομηθεί από το μοντέλο ως χαμηλού κινδύνου. Αυτά τα ψευδώς αρνητικά αποτελέσματα διερευνώνται πρώτα. Πολλά από τα παραδείγματα χαμηλού κινδύνου σε αυτή την κατηγορία παρουσίαζαν λεπτές ασυμμετρίες ή είχαν ήπιες χρωματικές διακυμάνσεις που μπορούσαν εύκολα να παραπλανήσουν το σύστημα και να τα χαρακτηρίσει ως χαμηλού κινδύνου. Επιπλέον, πολλές

από τις εικόνες περιείχαν τεχνικά προβλήματα, όπως μερική απόκρυψη λόγω μαλλιών, ανεπαρκή εστίαση ή ακατάλληλο κάδρο, όπου η βλάβη καταλαμβάνει μόνο ένα μικρό τμήμα της εικόνας που έχει ληφθεί. Επομένως, θα είναι κρίσιμο να εξεταστούν όχι μόνο τα δεδομένα εκπαίδευσης που χρησιμοποιήθηκαν για την ανάπτυξη του μοντέλου, αλλά και ο τρόπος με τον οποίο καταγράφονται οι εικόνες χρησιμοποιώντας τη συσκευή, καθώς και τα δύο έχουν σημαντική επίδραση στην απόδοση του μοντέλου.

Οι ίδιες αρχές ισχύουν και για τα ψευδώς θετικά αποτελέσματα, δηλαδή τις καλοήθεις βλάβες που έχουν προβλεφθεί ως υψηλού κινδύνου. Για παράδειγμα, ορισμένοι καλοήθεις σπίλοι παρουσιάζουν ακανόνιστα όρια και μοτίβα χρωματικών διακυμάνσεων παρόμοια με αυτά των κακοήθων βλαβών, επομένως το μοντέλο μπορεί να παρέχει υψηλή πιθανότητα κακοήθειας για αυτά τα παραδείγματα με βάση τα οπτικά στοιχεία που έχει στη διάθεσή του. Σε άλλες περιπτώσεις, η παρουσία έντονων σκιών, αντανάκλασεων ή αντικειμένων στο φόντο μπορεί να παρεμβαίνει στο δίκτυο, αποσπώντας την προσοχή από την ίδια τη βλάβη. Με την αναθεώρηση αυτών των αναπαραστάσεων, θα είναι δυνατό να βελτιωθεί η ακρίβεια του μοντέλου στο μέλλον, για παράδειγμα, αυξάνοντας τον βαθμό τεχνητών στοιχείων και την αύξηση των τριχών κατά τη διάρκεια της εκπαίδευσης και/ή εφαρμόζοντας μια λειτουργία τμηματοποίησης των βλαβών που θα μειώσει την επίδραση του περιβάλλοντος δέρματος και του φόντου στο αποτέλεσμα της πρόβλεψης.

Εκτός από την εξέταση μεμονωμένων αναπαραστάσεων εσφαλμένων ταξινομήσεων, μπορεί να γίνει ένα επιπλέον επίπεδο αξιολόγησης με την ανάλυση των σφαλμάτων με βάση συγκεκριμένες υποομάδες που περιέχονται στο σύνολο επικύρωσης. Για παράδειγμα, θα μπορούσε να αναλυθεί εάν ορισμένες βλάβες έχουν περισσότερες περιπτώσεις εσφαλμένων ταξινομήσεων με βάση τη θέση της βλάβης, συγκεκριμένα χρώματα και την πιθανοτική ομαδοποίηση πάνω ή γύρω από τα όρια των ζωνών κινδύνου. Αν και η πλήρης ανάλυση υποομάδων δεν εμπίπτει στο πεδίο εφαρμογής της παρούσας διατριβής, είναι δυνατό να προσδιοριστούν μοτίβα μέσω παρατηρήσεων του υπάρχοντος περιορισμένου συνόλου δεδομένων και του μοντέλου, τα οποία θα υποδείκνυαν τις περιοχές που απαιτούν βελτίωση. Επιπλέον, η ποιοτική αξιολόγηση των τρόπων αστοχίας του μοντέλου είναι αναπόσπαστο μέρος των επόμενων κεφαλαίων: η κατανόηση του λόγου των εσφαλμένων ταξινομήσεων υποστηρίζει τη λογική του συντηρητικού σχεδιασμού των ζωνών κινδύνου και της έκδοσης μιας ισχυρής δήλωσης αποποίησης ευθύνης στην εφαρμογή για κινητά, υπενθυμίζοντας στους πιθανούς χρήστες ότι ακόμη και ένας ταξινομητής με εξαιρετική απόδοση μπορεί να κάνει κλινικά σημαντικές εσφαλμένες ταξινομήσεις.

5.7 Ανακεφαλαίωση

Σε αυτό το κεφάλαιο περιγράφηκε ο τρόπος αξιολόγησης του εκπαιδευμένου μοντέλου και ο τρόπος επιλογής των ζωνών και των ορίων για τη χρήση των εφαρμογών της εφαρμογής για κινητά. Πρώτα, οι εκδόσεις Keras και TensorFlow lite αξιολογήθηκαν στο ίδιο σύνολο επικύρωσης για να αποδειχθεί ότι η ακρίβεια της λειτουργίας της μετατροπής σε TFLite δεν αλλάζει με ουσιαστικό τρόπο όσον αφορά τη συμπεριφορά ή την απόδοση. Στη συνέχεια, πραγματοποιήθηκε συστηματική αναζήτηση υποψήφιων ορίων στα αποτελέσματα του TFLite για τον προσδιορισμό των συμβιβασμών μεταξύ ευαισθησίας και ειδικότητας, ή ακραίων ορίων για τη διερεύνηση των συμβιβασμών μεταξύ ευαισθησίας και ειδικότητας. Στο πλαίσιο αυτής της ανάλυσης, επιλέχθηκαν χαμηλά και υψηλά όρια για να καταστεί δυνατή η χρήση της ζώνης πιθανότητας για τη δημιουργία ζωνών χαμηλού, μεσαίου και υψηλού κινδύνου, όπως ορίζονται για την κατηγοριοποίηση μιας πιθανής κακοήθους βλάβης σε ζώνη χαμηλού κινδύνου. Τέλος, η πολύτιμη ποιοτική εξέταση της μεταβλητότητας των σφαλμάτων συμβάλλει επίσης στην κατανόηση των συμπεριφορών και των ορίων στα οποία μπορεί να υποβληθεί το μοντέλο.

Οι μεθοδολογίες που περιγράφονται σε αυτό το κεφάλαιο παρέχουν μια δομημένη διαδικασία για τη δημιουργία μιας διαδικασίας αξιολόγησης και λήψης αποφάσεων σχετικά με τα αποτελέσματα των μοντέλων Keras και TensorFlow Lite (TFLite).

Ξεκινώντας με ένα αντιπροσωπευτικό δείγμα του συνόλου δεδομένων HAM10000, αυτό το κεφάλαιο δείχνει πώς να αναπτύξετε υπολογίσιμα μέτρα απόδοσης που παραμένουν σταθερά κατά τη μετάβαση από το αρχικό μοντέλο Keras στο TFLite. Θα εξετάσει αυτό το θέμα χρησιμοποιώντας τόσο κλασικές μετρήσεις (δηλ. καμπύλη χαρακτηριστικών λειτουργίας δέκτη, δείκτης Youden) όσο και περιορισμούς συγκεκριμένων συνθηκών στο τμήμα των κακοήθων βλαβών που βρίσκονται στην περιοχή χαμηλού κινδύνου. Το κεφάλαιο διερευνά επίσης τις συμβιβαστικές λύσεις που έγιναν κατά τη δημιουργία των επιπέδων υψηλού, μέσου και χαμηλού κινδύνου που θα συμπληρώσουν τη διεπαφή χρήστη της εφαρμογής για κινητά.

Τέλος, μέσω της ανάλυσης σφαλμάτων που πραγματοποιήθηκε, αυτό το κεφάλαιο αρέχει τη δυνατότητα ανάλυσης συγκεκριμένων σφαλμάτων πρόβλεψης του μοντέλου (δηλ. αποτυχία αναγνώρισης κακοήθων βλαβών), ειδικά στην κρίσιμη ζώνη χαμηλού κινδύνου. Αυτό θα αποτελέσει τη βάση για τη συντηρητική επικοινωνία των κινδύνων και την προετοιμασία για τις ηθικές και λειτουργικές επιπτώσεις, όπως θα αναπτυχθεί περαιτέρω στα επόμενα κεφάλαια.

Συμπερασματικά, το κεφάλαιο 5 παρουσίασε μια διαδικασία αξιολόγησης του μοντέλου και επιλογής λειτουργικών κατωφλίων, δίνοντας σημασία στις μετρήσεις απόδοσης και στους κρίσιμους περιορισμούς ασφάλειας. Η ανάλυση αυτή οριστικοποιεί τη μεταφορά από την ποσοτική αξιολόγηση του μοντέλου, στην σχεδίαση ζωνών κινδύνου κατάλληλες για εφαρμογή κινητού. Εκτός από την ανάπτυξη ενός προγράμματος εκπαίδευσης, ο ταξινομητής θα αξιολογηθεί διεξοδικά (πλεονεκτήματα/μειονεκτήματα), θα τεκμηριωθούν τα επιλεγμένα όρια, οι ζώνες κινδύνου και οι αντίστοιχες αιτιολογήσεις και θα δημιουργηθεί το εννοιολογικό πλαίσιο για την εφαρμογή των ιδεών σχεδιασμού σε εργαλείο υποστήριξης λήψης αποφάσεων για κινητά, όπως θα αναλυθεί στο κεφάλαιο 6.

Κεφάλαιο 6ο: Εξαγωγή μοντέλου και ενσωμάτωση σε κινητά

Σε αυτό το κεφάλαιο περιγράφεται η διαδικασία λήψης του εκπαιδευμένου μοντέλου, μετατροπής του σε TensorFlow Lite και ενσωμάτωσής του σε μια εφαρμογή για κινητά. Ο σκοπός είναι να παρουσιαστεί πώς ένα πειραματικό μοντέλο που έχει δημιουργηθεί στο περιβάλλον εκπαίδευσης μετατρέπεται σε ένα ενσωματωμένο σύστημα που εκτελείται σε ένα smartphone.

6.1 Μετατροπή σε TensorFlow Lite

Μόλις ολοκληρωθεί η εκπαίδευση, το μοντέλο με την καλύτερη απόδοση αποθηκεύεται σε μορφή Keras (στο δίσκο). Όπως και με το αρχικό μοντέλο Keras, το αποθηκευμένο μοντέλο Keras ενσωματώνει τόσο το ConvNeXt-Tiny backbone όσο και τα πρόσθετα επίπεδα που ορίζονται στο κεφάλαιο 5. Το μοντέλο Keras είναι το σημείο εκκίνησης για τη μετατροπή σε TensorFlow Lite. Για τη μετατροπή χρησιμοποιείται ο τυπικός μετατροπέας TensorFlow Lite, ο οποίος έχει ρυθμιστεί ώστε να δέχεται μοντέλα Keras ως είσοδο (είτε από δίσκο είτε από μνήμη) και να παράγει ένα ή περισσότερα μοντέλα .tflite που περιλαμβάνουν την ίδια αρχιτεκτονική και τα ίδια βάρη σε μορφή που είναι βελτιστοποιημένη για ανάπτυξη σε περιβάλλοντα κινητών συσκευών. Το TensorFlow Lite έχει δημιουργηθεί με στόχο τη διευκόλυνση της εξαγωγής των συμπερασμάτων μηχανικής μάθησης απευθείας στη συσκευή. Παρέχει μικρότερο μέγεθος μοντέλου και αυξάνει την ταχύτητα σε κινητές πλατφόρμες και ενσωματωμένα συστήματα [22].

Σε αυτό το project, παρήχθησαν διάφορες παραλλαγές μοντέλων TensorFlow Lite. Ένα μοντέλο float32, το οποίο διατηρεί την πλησιέστερη αριθμητική πιστότητα στο αρχικό μοντέλο Keras, έχει παραχθεί ως βάση αναφοράς. Πρόσθετες παραλλαγές παράχθηκαν χρησιμοποιώντας είτε κβαντοποίηση δυναμικού εύρους είτε βάρη float16, για να μειωθεί το μέγεθος του αρχείου και/ή ο χρόνος συμπερασμού σε συσκευές που το επιτρέπουν. Αυτά τα κβαντοποιημένα μοντέλα συνεπάγονται κάποια απώλεια αριθμητικής πιστότητας για λόγους αποδοτικότητας. Όλες οι παραλλαγές έχουν τις ίδιες διεπαφές εισόδου και εξόδου.

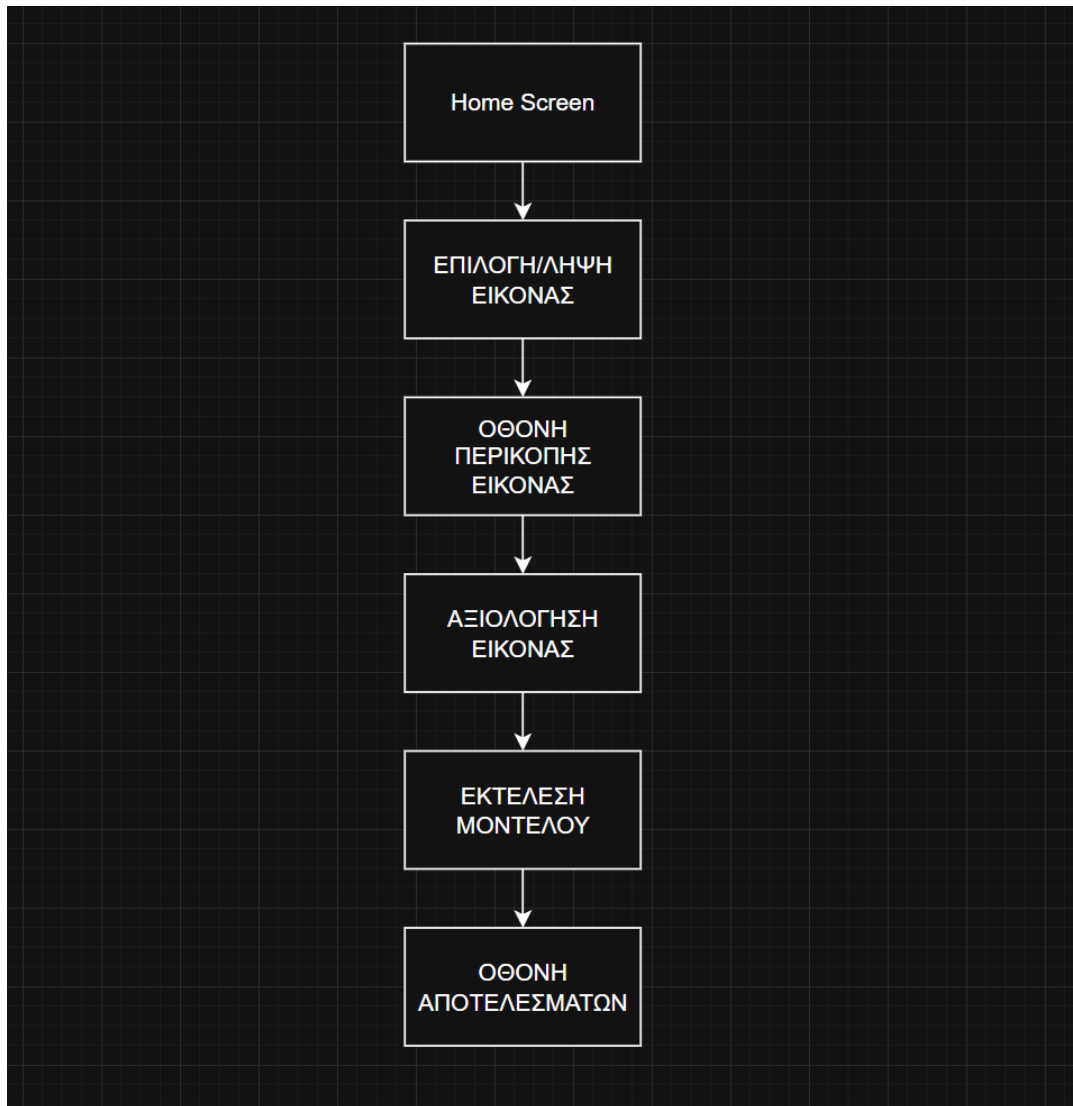
Η σύγκριση αυτών των πιθανοτήτων με τις αρχικές πιθανότητες από το μοντέλο Keras στις ίδιες εικόνες μπορεί να επαληθεύσει ότι η μετατροπή δεν εισήγαγε μεγάλη διαφορά. Για κάθε εξαγόμενη παραλλαγή, εφαρμόστηκε ο ίδιος έλεγχος ορθότητας και, όπου ήταν δυνατό, επιλέχθηκε για συμπερίληψη στην εφαρμογή η παραλλαγή της οποίας τα αποτελέσματα ταιριάζουν καλύτερα με το Keras, ενώ εξακολουθεί να επιτρέπει κατάλληλο μέγεθος και ταχύτητα.

Το τελικό επιλεγμένο αρχείο .tflite αντιγράφεται στη συνέχεια στο πρόγραμμα για κινητά. Μόλις το μοντέλο συμπεριληφθεί στο πρόγραμμα για κινητά, ο κώδικας για κινητά μπορεί να φορτώσει το μοντέλο κατά την εκτέλεση και να εκτελέσει την εξαγωγή συμπερασμάτων σε μια εικόνα που έχει ανεβάσει ο χρήστης.

Μόλις ένα μοντέλο Keras ή ένα σημείο ελέγχου μετατραπεί σε TensorFlow Lite, μπορούν να δημιουργηθούν πολλαπλοί τύποι μοντέλων TensorFlow Lite Variant από το ίδιο σημείο ελέγχου Keras. Ένα μοντέλο float32 σε πλήρη ακρίβεια προσφέρει συμπεριφορά παρόμοια με το αρχικό έργο Keras, αν και μπορεί να μην είναι η πιο αποτελεσματική επιλογή σε συσκευές χαμηλότερης απόδοσης λόγω του μεγέθους του. Τα κβαντισμένα μοντέλα υπάρχουν ως μοντέλα float16 ή δυναμικού εύρους, τα οποία επιτρέπουν μικρότερο αποτύπωμα μνήμης και ενδεχομένως ταχύτερο χρόνο συμπερασμού, με ελάχιστη μείωση της αριθμητικής ακρίβειας. Καθώς η ερευνητική μελέτη μετατρέπει μοντέλα Keras σε μοντέλα TensorFlow Lite, χρησιμοποιεί το τυπικό API μετατροπέα TFLite για να δημιουργήσει πολλαπλά υποψήφια αρχεία .tflite με βάση τις επιλογές βελτιστοποίησης που έχουν επιλεγεί. Όλα τα υποψήφια μοντέλα έχουν τις ίδιες διεπαφές εισόδου και εξόδου. Ωστόσο, οι υποκείμενες αναπαραστάσεις που χρησιμοποιούνται για κάθε υποψήφιο μοντέλο θα είναι μοναδικές μεταξύ τους.

Για να διασφαλιστεί ότι η μετατροπή σε μοντέλα TensorFlow Lite δεν άλλαξε σημαντικά τη συμπεριφορά του μοντέλου Keras, ένα μικρό σενάριο Python φορτώνει κάθε ένα από τα υποψήφια αρχεία .tflite στο `tf.lite.Interpreter` και τα εκτελεί στις ίδιες εικόνες επικύρωσης που χρησιμοποιήθηκαν στο Κεφάλαιο 5. Το σενάριο καταγράφει την ετικέτα `ground-truth` για κάθε εικόνα μαζί με τις πιθανότητες που υπολογίζονται από το μοντέλο TFLite, και αυτές οι τιμές συγκρίνονται με τις πιθανότητες του αρχικού μοντέλου Keras. Τα υποψήφια μοντέλα με διαφορές της τάξης μεγέθους 10^{-3} (που ισοδυναμεί με 0,001) έως 10^{-6} (που ισοδυναμεί με 0,000001) που δεν επηρεάζουν σημαντικά την κατάταξη των δειγμάτων ή τις κύριες μετρήσεις επικύρωσης σε βασικά όρια θεωρούνται αριθμητικά αποδεκτά.

Μόλις προσδιοριστούν οι συμβιβασμοί μεταξύ της απόδοσης του μοντέλου (μέγεθος, ταχύτητα, πιστότητα), το τελικό επιλεγμένο αρχείο .tflite τοποθετήθηκε στο έργο για κινητά ως στατικό στοιχείο. Σε αυτό το σημείο, το περιβάλλον εκπαίδευσης δεν είναι πλέον απαραίτητο. Η εφαρμογή για κινητά θα λάβει το μοντέλο TensorFlow Lite κατά την εκτέλεση για να πραγματοποιήσει συμπεράσματα χρησιμοποιώντας εικόνες που παρέχονται από τους χρήστες. Στις υπόλοιπες ενότητες αυτού του κεφαλαίου θα εξηγηθεί πώς να ενσωματώσετε αυτό το μοντέλο σε μια εφαρμογή Flutter και πώς να μεταφράσετε την πιθανολογική έξοδο από το μοντέλο σε πληροφορίες κινδύνου ορατές στους χρήστες.



Σχήμα 6.1: Διάγραμμα ροής αλληλεπίδρασης χρήστη εφαρμογής

6.2 Αρχιτεκτονική εφαρμογής και ενσωμάτωση μοντέλου

Η εφαρμογή για κινητά υλοποιείται στο Flutter, χρησιμοποιώντας μια βασική αρχιτεκτονική με περιορισμένο αριθμό οθονών και κλάσεων. Η κυρίαρχη ροή για τον χρήστη αποτελείται από μια αρχική οθόνη, η οποία επιτρέπει στον χρήστη να επιλέξει ή να τραβήξει μια φωτογραφία, μια οθόνη φόρτωσης, η οποία εμφανίζεται ενώ εκτελείται ο έλεγχος ποιότητας εικόνας και η συμπερασματολογία, και την οθόνη αποτελεσμάτων, η οποία περιέχει τις σχετικές πληροφορίες κινδύνου. Υποστηρίζοντας αυτές τις οθόνες και σχετιζόμενες με το σχετικό επίπεδο που υλοποιεί το μοντέλο, υπάρχουν εξειδικευμένες υπηρεσίες που υλοποιούν την ανάλυση εικόνας και την εξαγωγή συμπερασμάτων του μοντέλου.

Η ενσωμάτωση του μοντέλου αντιπροσωπεύεται από την υπηρεσία συμπερασμού. Αυτή η υπηρεσία χειρίζεται τη φόρτωση του μοντέλου TensorFlow Lite από τα στοιχεία της εφαρμογής, δημιουργώντας έναν διερμηνέα TensorFlow Lite, διαμορφώνοντας τον διερμηνέα και, στη συνέχεια, παρέχοντας μια απλή μέθοδο που δέχεται μια εικόνα ως είσοδο και επιστρέφει μια εκτίμηση πιθανότητα κακοήθειας ως έξοδο. Ο διερμηνέας δημιουργείται συχνά μία φορά και επομένως επαναχρησιμοποιείται για επόμενες κλήσεις, προκειμένου να μετριαστεί το επιπλέον κόστος της επαναλαμβανόμενης αρχικοποίησης (και να εξοικονομηθούν μερικά χιλιοστά του δευτερολέπτου στην ταχύτητα συμπερασμού).

Όταν ο χρήστης επιλέγει μια εικόνα από τη συλλογή ή τραβά μια νέα φωτογραφία με την κάμερα, η εφαρμογή εμφανίζει μια διεπαφή περικοπής, επιτρέποντας την κεντράρισμα της μεμονωμένης βλάβης

και την περικοπή του μεγαλύτερου μέρους του άσχετου φόντου. Αφού ο χρήστης συμφωνήσει με την περικοπή, παίρνουμε την εικόνα που προκύπτει και την υποβάλλουμε σε ένα βήμα προεπεξεργασίας που μιμείται (όσο το δυνατόν πιο πιστά) τα βήματα που χρησιμοποιούνται κατά την εκπαίδευση - η εικόνα αλλάζει μέγεθος σε 256 x 256 pixels, μετατρέπεται σε χρωματικό χώρο RGB (εάν χρειάζεται να μετατραπεί) και στη συνέχεια αποθηκεύεται στην αριθμητική μορφή που απαιτεί ο διερμηνέας TensorFlow Lite. Μετά την προεπεξεργασία, η εικόνα μεταφέρεται στην είσοδο του διερμηνέα, ο οποίος εκτελεί το μοντέλο και επιστρέφει έναν αριθμό κινητής υποδιαστολής μεταξύ 0 και 1.

Η υπηρεσία συμπεράσματος λαμβάνει αυτή την ακατέργαστη έξοδο και τη μεταφράζει σε ένα «απλό» αντικείμενο αποτελέσματος που περιέχει την πιθανότητα και, προαιρετικά, τη σχετική δυαδική απόφαση στο όριο αναφοράς. Τα στοιχεία ανώτερου επιπέδου της εφαρμογής παραμένουν χωρίς καμία πληροφορία σχετικά με το μοντέλο και χρησιμοποιούν απλώς αυτό το αντικείμενο αποτελέσματος. Αυτό διαχωρίζει τον κώδικα της διεπαφής χρήστη και επιτρέπει την πραγματοποίηση αλλαγών στο backend του μοντέλου στο μέλλον, για παράδειγμα με την παροχή ενός διαφορετικού αρχείου .tflite, αρκεί να μην επηρεάζεται η ροή της εφαρμογής.

Η εφαρμογή για κινητά χρησιμοποιεί μια πολυεπίπεδη προσέγγιση για να διαχωρίσει τη διεπαφή χρήστη (UI) από τις πτυχές της μηχανικής μάθησης (ML) της εφαρμογής για κινητά. Η ροή εργασίας του χρήστη αποτελείται από τρεις οθόνες που αποτελούνται από widget Flutter: Η οθόνη MelanomaCheckHome επιτρέπει στον χρήστη να τραβήξει ή να ανεβάσει μια εικόνα των ύποπτων βλαβών. Η οθόνη φόρτωσης, η οποία εκτελεί ελέγχους ποιότητας και επεξεργάζεται την εικόνα μέσω του αλγορίθμου ML στη συσκευή. Και τέλος, η οθόνη αποτελεσμάτων, η οποία παρέχει στον χρήστη την εκτίμηση κινδύνου και τυχόν σχετικές δηλώσεις αποποίησης ευθύνης. Η πλοήγηση στις τρεις οθόνες χρησιμοποιεί τυπικές τεχνικές δρομολόγησης που είναι διαθέσιμες με το Flutter και, σε κάθε βήμα, ένα δομημένο αντικείμενο επιστρέφεται στο προηγούμενο widget.

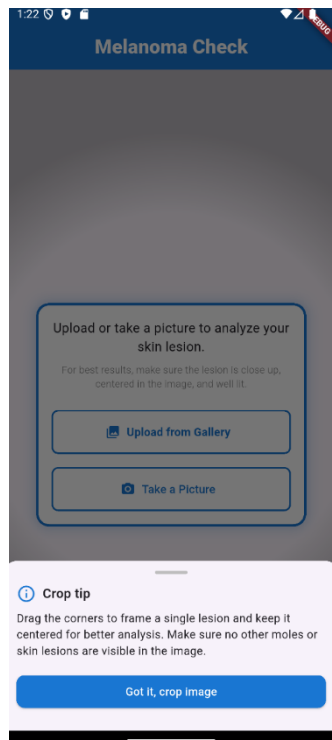

Η ενσωμάτωση του υποκείμενου μοντέλου μηχανικής μάθησης είναι ενσωματωμένη σε μια ξεχωριστή κλάση που ονομάζεται InferenceService. Αυτή η κλάση είναι υπεύθυνη για τη φόρτωση του αρχείου μοντέλου .tflite από το πακέτο στοιχείων και τη δημιουργία ενός διερμηνέα με τον αριθμό νημάτων που καθορίζεται από τον χρήστη, καθώς και για την προετοιμασία των τανυστών εισόδου και εξόδου για χρήση. Κατά τη δημιουργία μιας παρουσίας αυτής της κλάσης, θα φορτωθεί επίσης ένα αρχείο ετικετών, επιτρέποντας τη χρήση της ίδιας κλάσης για μελλοντικά μοντέλα ML πολλαπλών κλάσεων. Το InferenceService έχει μία μέθοδο υψηλού επιπέδου που ονομάζεται run(File imageFile), η οποία λαμβάνει ένα αρχείο εικόνας, το αποκωδικοποιεί, το κανονικοποιεί σύμφωνα με τις απαιτήσεις του μοντέλου και, στη συνέχεια, ενημερώνει τον διερμηνέα να παρέχει την τελική έξοδο σε ένα δομημένο αντικείμενο αποτελέσματος.

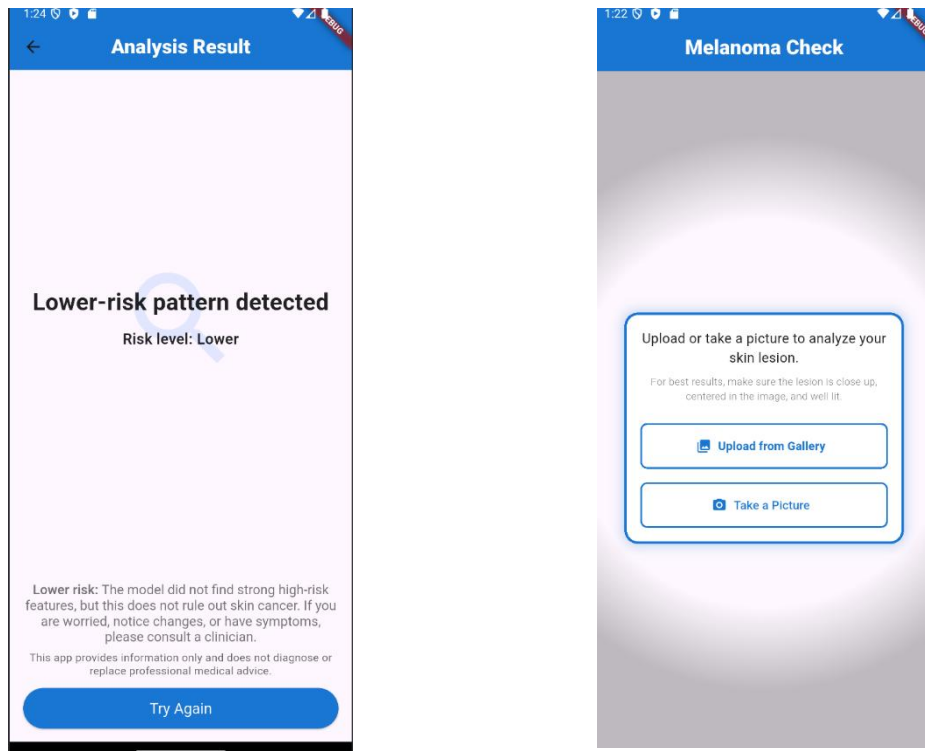
Αυτός ο σχεδιασμός παρέχει σημαντικό διαχωρισμό της διεπαφής χρήστη και της συμπερασματολογίας μοντέλου. Τα στοιχεία της διεπαφής χρήστη δεν θα επικοινωνούν απευθείας με το API του TensorFlow Lite, αλλά θα θεωρούν το InferenceService ως ένα μαύρο κουτί που λαμβάνει μια εικόνα και παρέχει έξοδο με τη μορφή πιθανότητας ότι η βλάβη είναι κακοήθης. Για παράδειγμα, για μια εικόνα που περνά τους ελέγχους ποιότητας στην οθόνη φόρτωσης, η εφαρμογή δημιουργεί μια παρουσία του InferenceService, καλεί τη μέθοδο run() και ανακτά έναν δείκτη εμπιστοσύνης από το αποτέλεσμα. Επομένως, εάν μια μελλοντική έκδοση αυτής της εφαρμογής χρησιμοποιεί ένα διαφορετικό μοντέλο μηχανικής μάθησης ή ακόμη και μια εντελώς διαφορετική τεχνολογία, η διεπαφή χρήστη θα συνεχίσει να λειτουργεί χωρίς αλλαγές στον κώδικα, υπό την προϋπόθεση ότι το InferenceService έχει τροποποιηθεί ώστε να επιστρέφει αποτελέσματα με παρόμοιο τρόπο.

Το ResultScreen λειτουργεί με βάση την έξοδο που δημιουργείται από το InferenceService. Λαμβάνει ένα hashmap που περιέχει τόσο τον υπολογισμένο δείκτη εμπιστοσύνης από το μοντέλο, όσο και τυχόν βαθμολογίες που σχετίζονται με την έκδοση του μοντέλου που δημιούργησε τον δείκτη εμπιστοσύνης,

Εξαγωγή μοντέλου και ενσωμάτωση σε κινητά

και το μεταφράζει σε μια σωστά περιορισμένη βαθμολογία πιθανότητας που κυμαίνεται από 0 έως 1. Στη συνέχεια, συσχετίζει αυτήν την τιμή με ένα επίπεδο κινδύνου χρησιμοποιώντας όρια που δημιουργήθηκαν στο Κεφάλαιο 5. Σε κανένα σημείο του κύκλου ζωής του ResultScreen δεν έχει γνώση σχετικά με το ποιο αρχείο .tflite χρησιμοποιήθηκε, πώς κβαντίστηκε το μοντέλο ML ή ποια είναι η συγκεκριμένη αρχιτεκτονική του μοντέλου ML που δημιούργησε την πιθανότητα.





Σχήμα 6.2: Ενδεικτικά Screenshot εφαρμογής

6.3 Αξιολόγηση της ποιότητας της εικόνας στη συσκευή

Πριν το μοντέλο αναλύσει την εικόνα, η εφαρμογή εκτελεί μια ελαφριά αξιολόγηση της ποιότητας της εικόνας στη συσκευή, η οποία γίνεται σε ένα ξεχωριστό module ανάλυσης εικόνας. Αυτή η λογική στοχεύει στην απόρριψη εικόνων που είναι πολύ απίθανο να αποδώσουν έγκυρες προβλέψεις, επειδή είναι υπερβολικά θολές, έχουν πολύ λίγη ορατή επιδερμίδα ή δεν πληρούν τα βασικά κριτήρια σύνθεσης και καδράρισμα της εικόνας.

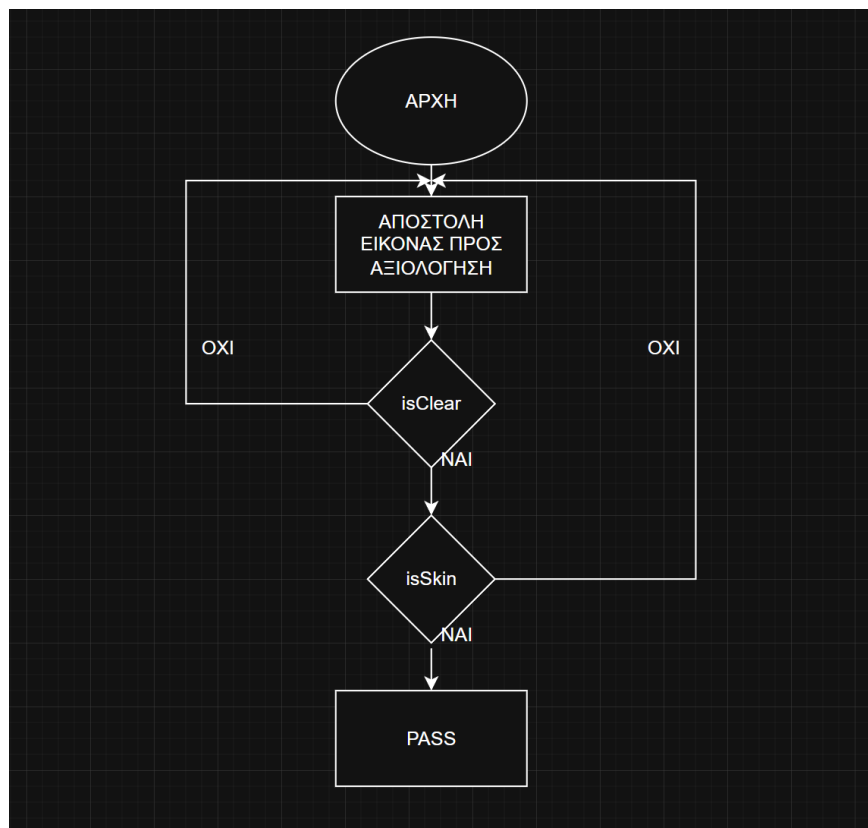
Για αξιολόγηση της ποιότητας χρησιμοποιείται ένας περιορισμένος συνδυασμός ερευνητικών μεθόδων χαμηλού υπολογιστικού κόστους. Για να προσδιοριστεί η ευκρίνεια, η μονάδα υπολογίζει μια αριθμητική βαθμολογία με βάση τις διαφορές έντασης των εικονοστοιχείων στην τοπική περιοχή μιας εικόνας, για παράδειγμα χρησιμοποιώντας μια βαθμολογία εστίασης βασισμένη στο Laplacian. Παρόμοιες μετρικές που βασίζονται στη διακύμανση του Laplacian έχουν βρει εκτενή εφαρμογή στην αυτόματη ανίχνευση θολών εικόνων στον τομέα της υπολογιστικής όρασης [24]. Εάν η βαθμολογία ευκρίνειας που προκύπτει είναι κάτω από ένα προκαθορισμένο όριο, η εικόνα είναι πολύ θολή.

Για να διαπιστωθεί εάν η εικόνα περιέχει πράγματι μια βλάβη στο δέρμα, χρησιμοποιείται ένας στοιχειώδης αλγόριθμος ανίχνευσης δέρματος για να ταξινομηθούν τα pixel ως δέρμα ή μη δέρμα με βάση το χρώμα τους σε έναν κατάλληλο χρωματικό χώρο. Στη βιβλιογραφία έχουν προταθεί διάφορες μέθοδοι ανίχνευσης δέρματος, οι οποίες συχνά στηρίζονται σε κατωφλιοποίηση σε χρωματικούς χώρους όπως είναι οι HSV και YCbCr ή χρησιμοποιούν συνδυαστικά πιθανά μοντέλα [25]. Στη συνέχεια, υπολογίζεται η αναλογία των pixel δέρματος προς τα pixel της εικόνας. Εάν δεν υπάρχουν αρκετά pixel δέρματος ή το δέρμα καλύπτεται από φυλλάματα, ρούχα ή άλλα αντικείμενα, η αναλογία θεωρείται πολύ χαμηλή.

Από την πλευρά του Flutter, έχουμε ενσωματώσει αυτούς τους ελέγχους στο widget LoadingScreenWithAnalysis. Αφού ο χρήστης περικόψει τη φωτογραφία του ή επιλέξει μια εικόνα, η εφαρμογή θα καλέσει μια συνάρτηση analyzeImage που χρησιμοποιεί τη λογική που αναφέρθηκε παραπάνω και επιστρέφει μια δομημένη ένδειξη επιτυχίας ή αποτυχίας της αξιολόγησης ποιότητας. Εάν οποιαδήποτε από αυτές τις συνθήκες είναι ψευδής, η οθόνη φόρτωσης θα επιστρέψει στην

προηγούμενη οθόνη με κατάσταση αποτυχίας, μαζί με ένα ευανάγνωστο μήνυμα (π.χ. «Η εικόνα σας δεν είναι αρκετά καθαρή» ή «Η εικόνα σας δεν έχει αρκετό δέρμα»). Στη συνέχεια, οι χρήστες θα λάβουν οδηγίες να ξαναπάρουν τη φωτογραφία με καλύτερο φωτισμό ή με πιο στενή περικοπή. Μόνο οι φωτογραφίες που είναι αρκετά καθαρές και έχουν επαρκή ποσότητα δέρματος θα υποβληθούν σε επεξεργασία από το μοντέλο κατά τη διάρκεια της εξαγωγής συμπερασμάτων.

Αν και οι ευριστικές τεχνικές δεν παρέχουν ποτέ 100% εγγυημένη ποιότητα εικόνας, αντιπροσωπεύουν ένα βασικό πρώτο επίπεδο άμυνας ενάντια στα χειρότερα δεδομένα. Εκτός από την προστασία του μοντέλου από τα χειρότερα δεδομένα, βελτιώνουν τη μέση ποιότητα των αναλυόμενων εικόνων και αυξάνουν την προβλεψιμότητα της συμπεριφοράς του ίδιου του συστήματος. Τέλος, καταδεικνύουν μια σημαντική πτυχή του σχεδιασμού για το έργο συνολικά. Αντί να βασιζόμαστε σε ένα νευρωνικό δίκτυο για να χειριστούμε όλα τα αποτελέσματα, σχεδιάσαμε την εφαρμογή ώστε να χρησιμοποιεί στοιχεία μηχανικής μάθησης με παραδοσιακή επεξεργασία εικόνας και στοιχεία σχεδιασμού αλληλεπίδρασης, σε μια προσπάθεια να προωθήσουμε ένα υψηλότερο επίπεδο ποιότητας δεδομένων.



Σχήμα 6.3: Αναλυτικό διάγραμμα ροής αξιολόγησης εικόνας

6.4 Αντιστοίχιση πιθανοτήτων με μηνύματα κινδύνου

Το μοντέλο TensorFlow Lite παράγει μια πιθανότητα κακοήθειας, την οποία η εφαρμογή δεν εμφανίζει άμεσα. Αντ' αυτού, η εφαρμογή θα χρησιμοποιήσει τα χαμηλά και υψηλά όρια που καθορίζονται στο κεφάλαιο 5 για να αντιστοιχίσει την πιθανότητα σε μία από τις τρεις κατηγορίες κινδύνου. Η μετατροπή των αριθμητικών πιθανοτήτων σε απλές κατηγορίες κινδύνου είναι συμβατή με τις προτάσεις της βιβλιογραφίας, που στοχεύουν στη διευκόλυνση της επικοινωνίας του κινδύνου προς άτομα που δεν έχουν ειδικές γνώσεις [32][26]. Θα αποδώσει χαμηλότερο κίνδυνο εάν η πιθανότητα είναι μικρότερη

από το χαμηλό όριο, θα αποδώσει αβέβαιο ή ενδιάμεσο κίνδυνο εάν η πιθανότητα βρίσκεται μεταξύ του χαμηλού και του υψηλού ορίου και θα αποδώσει υψηλότερο κίνδυνο εάν η πιθανότητα είναι μεγαλύτερη από το υψηλό όριο.

Η αντιστοίχιση πραγματοποιείται στη λογική της οθόνης αποτελεσμάτων. Αφού η υπηρεσία εξαγωγής συμπερασμάτων παρέχει μια πιθανότητα, η οθόνη αποτελεσμάτων επεξεργάζεται την κατηγορία κινδύνου και καθορίζει τον σχετικό τίτλο και το επεξηγηματικό κείμενο. Για παράδειγμα, το μήνυμα χαμηλού κινδύνου μπορεί να επισημάνει ότι το μοτίβο ταιριάζει περισσότερο με τις καλοήθειες βλάβες στα δεδομένα εκπαίδευσης, ενώ ταυτόχρονα να σημειώνει ότι αυτό δεν αποκλείει την ύπαρξη ασθένειας. Το μήνυμα στην ενδιάμεση ζώνη μπορεί να τονίζει την αβεβαιότητα και να προειδοποιεί τον αναγνώστη να παρακολουθεί τις αλλαγές ή να συμβουλευτεί έναν κλινικό γιατρό. Τέλος, το μήνυμα υψηλότερου κινδύνου θα τονίζει ότι το μοτίβο έχει χαρακτηριστικά παρόμοια με τα κακοήθη βλάβες και θα παρέχει μια ισχυρή σύσταση για μια άμεση ιατρική αξιολόγηση. Σε κάθε περίπτωση, η οθόνη αποτελεσμάτων περιλαμβάνει μια αυστηρή προειδοποίηση ότι η εφαρμογή δεν ισχυρίζεται ότι παρέχει διάγνωση και δεν μπορεί να αποκλείσει την πιθανότητα καρκίνου. Η οθόνη δηλώνει ότι η αξιολόγηση του μοντέλου βασίζεται αποκλειστικά στην εικόνα που υποβλήθηκε και ότι για τη διάγνωση είναι απαραίτητο το σύνολο του πλαισίου - ιατρικό ιστορικό, φυσική αξιολόγηση, ιστοπαθολογία κ.λπ. Η οθόνη συμβουλεύει επίσης τους ασθενείς να παρακολουθούν τις βλάβες για να δουν αν αλλάζουν και να συμβουλευτούν έναν γιατρό το συντομότερο δυνατόν εάν η βλάβη μεγαλώσει, αιμορραγεί, εμφανίσει συμπτώματα ή εξελιχθεί με οποιονδήποτε ανησυχητικό τρόπο, ανεξάρτητα από τα αποτελέσματα της εφαρμογής.

Κάθε μία από τις τρεις κατηγορίες κινδύνου περιέχει διαφορετικά μηνύματα και επεξηγηματικό κείμενο στη σελίδα τεκμηρίωσης αποτελεσμάτων. Το μήνυμα για τα αποτελέσματα χαμηλού κινδύνου παρέχει ηθική προειδοποίηση και διαβεβαίωση σχετικά με τα ευρήματα της υπό συζήτηση βλάβης. Ο χρήστης ενημερώνεται ότι φαίνεται να υπάρχει χαμηλή πιθανότητα να πρόκειται για κακοήθη βλάβη, αλλά υπενθυμίζεται επίσης ότι πρέπει να συνεχίσει να παρακολουθεί την υγεία του δέρματός του και να επικοινωνεί με τον γιατρό του σχετικά με οποιεσδήποτε αλλαγές στην υγεία του δέρματός του. Το μήνυμα για τα αποτελέσματα μεσαίου κινδύνου υποδεικνύει ότι υπάρχει αβεβαιότητα σχετικά με τα ευρήματα και ότι ο χρήστης ενθαρρύνεται να ζητήσει ιατρική αξιολόγηση για να διευκρινίσει τα ευρήματα. Για τα αποτελέσματα υψηλού κινδύνου, το μήνυμα γίνεται πιο επείγον στη διατύπωσή του και ενθαρρύνει τον χρήστη να ζητήσει επαγγελματική αξιολόγηση το συντομότερο δυνατόν. Όλα τα μηνύματα στην εφαρμογή δηλώνουν σαφώς ότι η εφαρμογή δεν παρέχει διαγνώσεις, αλλά εκτιμήσεις κινδύνου με βάση μοντέλα μηχανικής μάθησης.

Τα μηνύματα που κοινοποιούνται στους χρήστες έχουν σχεδιαστεί με βάση αποδεκτές κατευθυντήριες γραμμές για την επικοινωνία του κινδύνου. Αυτές οι κατευθυντήριες γραμμές υποδεικνύουν ότι η πιθανότητα κινδύνου είναι πιο εύκολα κατανοητή όταν εκφράζεται ως ποιοτικές κατηγορίες με σαφείς συμβουλές προσανατολισμένες στη δράση, σε σύγκριση με την έκφραση ως ακατέργαστα ποσοστά. Ιστορικές μελέτες σχετικά με την ιατρική επικοινωνία του κινδύνου έχουν δείξει ότι οι μη ειδικοί μπορούν εύκολα να παρερμηνεύσουν τις αριθμητικές πιθανότητες, ειδικά όταν το βασικό ποσοστό δεν είναι σαφές. Με τη μείωση των μεγάλων πιθανοτήτων σε μικρότερο αριθμό ονομαστικών επιπέδων κινδύνου, οι πληροφορίες γίνονται πιο κατανοητές και είναι λιγότερο πιθανό να παρερμηνευθούν. Αυτό είναι ιδιαίτερα σημαντικό για μια εφαρμογή για κινητά που έχει σχεδιαστεί για χρήση από μη ειδικούς χρήστες, όπου δεν θα υπάρχει διαθέσιμος ιατρός για να βοηθήσει τον χρήστη να κατανοήσει τα νούμερα στο πλαίσιο τους.

Μια δήλωση αποποίησης ευθύνης τοποθετήθηκε σε εμφανές σημείο στη σελίδα τεκμηρίωσης αποτελεσμάτων, προκειμένου να ενημερώνονται οι χρήστες για την ανάγκη να λάβουν ανεξάρτητη ιατρική συμβουλή και ότι ο σκοπός της εφαρμογής είναι να υποστηρίξει τον χρήστη στη λήψη αποφάσεων σχετικά με την υγεία του δέρματός του, και όχι να παρέχει οριστικές διαγνώσεις. Οι δηλώσεις αποποίησης ευθύνης, σε συνδυασμό με τα συντηρητικά όρια που αναφέρθηκαν νωρίτερα σε αυτό το κεφάλαιο, παρέχουν έναν κατάλληλο τρόπο για να πλαισιωθεί η εφαρμογή ως εργαλείο

υποστήριξης λήψης αποφάσεων και όχι ως διαγνωστική αρχή. Η διαδικασία αντιστοίχισης των πιθανοτήτων με τα μηνύματα κινδύνου είναι, επομένως, μια μαθηματική πράξη, καθώς και ένα σημαντικό μέρος του ηθικού σχεδιασμού της εφαρμογής.

6.5 Σύνοψη

Σε αυτό το κεφάλαιο περιεγράφηκε η διαδικασία εξαγωγής του εκπαιδευμένου μοντέλου και η ενσωμάτωσή του στην εφαρμογή Flutter μέσω της μετατροπής του σε TensorFlow Lite. Η ανάλυση στη συσκευή φορτώνει το μοντέλο και προετοιμάζει τις περικομμένες και αναδιαμορφωμένες εικόνες της αναλυθείσας βλάβης και επιστρέφει την πιθανότητα κακοήθειας με προκαθορισμένα όρια που αντιστοιχεί σε τρεις κατηγορίες κινδύνου.

Σε αυτό το κεφάλαιο, εξετάσαμε την πλήρη ανάπτυξη ενός προγνωστικού μοντέλου από μια ερευνητική πλατφόρμα έως ένα υλοποιημένο εργαλείο λογισμικού. Το μοντέλο Keras με την καλύτερη απόδοση μετατράπηκε σε μία ή περισσότερες εκδόσεις TensorFlow Lite (.tflite), βελτιστοποιημένες για συμβιβασμούς μεταξύ αριθμητικής ακρίβειας, μεγέθους μοντέλου και ταχύτητας συμπερασμού. Επαληθεύσαμε ότι το μοντέλο .tflite που προέκυψε λειτουργεί όπως αναμενόταν με βάση το αρχικό μας μοντέλο, επιβεβαιώνοντας ότι το μοντέλο μπορεί να χρησιμοποιηθεί αξιόπιστα με τα όρια κινδύνου.

Από την πλευρά της εφαρμογής, συζητήσαμε πώς το πλαίσιο Flutter οργανώνει τη ροή εργασίας της εφαρμογής σε έναν μικρό αριθμό στοιχείων οθόνης και υπηρεσιών. Η υπηρεσία συμπερασμού (Inference Service) παρέχει μια καθαρή διεπαφή για το μοντέλο συμπερασμού που λαμβάνει προεπεξεργασμένες εικόνες και παράγει πιθανότητες κακοήθειας. Τα στοιχεία της διεπαφής χρήστη δεν εξαρτώνται από την εσωτερική λειτουργία του μοντέλου συμπερασμού, γεγονός που επιτρέπει στους τελικούς χρήστες που ενδέχεται να έχουν ελάχιστη κατανόηση του τρόπου εκπαίδευσης του μοντέλου να έχουν πρόσβαση στην έξοδο που παράγεται από την υπηρεσία εξαγωγής συμπερασμάτων. Οι έλεγχοι ποιότητας στη συσκευή φιλτράρουν τις προ-επεξεργασμένες εικόνες κακής ποιότητας πριν φτάσουν στον ταξινομητή, μεγιστοποιώντας έτσι την ανθεκτικότητα του ταξινομητή.

Τα μοντέλα που αναπτύχθηκαν αντιστοιχίστηκαν σε κατηγορίες χαμηλού, μεσαίου και υψηλού κινδύνου, καθιστώντας έτσι δυνατή τη σύνδεση των τεχνικών πτυχών της διαδικασίας εκπαίδευσης και αξιολόγησης του μοντέλου με την ανθρωποκεντρική ανάγκη για αποτελεσματική επικοινωνία του κινδύνου. Συγκρίσεις συνόλων επικύρωσης, σε συνδυασμό με αποδεκτές μεθοδολογίες βασισμένες στη βιβλιογραφία, χρησιμοποιήθηκαν για να θεμελιώσουν τις αντιστοιχίσεις ορίων κινδύνου που μετατρέπουν τα αριθμητικά αποτελέσματα ενός μοντέλου πρόβλεψης τύπου «μαύρου κουτιού» σε πρακτικές και κατανοητές οδηγίες για τους τελικούς χρήστες. Τα όρια κινδύνου που καθορίστηκαν ήταν σκόπιμα συντηρητικά και περιλάμβαναν ισχυρές δηλώσεις αποποίησης ευθύνης που ανέφεραν ότι, παρόλο που το σύστημα παρέχει καθοδήγηση, δεν πρέπει να θεωρείται ως υποκατάστατο της κρίσης του ιατρού.

Συνολικά, αυτά τα στοιχεία παρέχουν το πλαίσιο για την ανάπτυξη αυτού του μοντέλου σε μια χρήσιμη, πραγματική εφαρμογή. Τα επόμενα κεφάλαια θα βασιστούν σε αυτό το θεμέλιο, συζητώντας τις επιπτώσεις της χρήσης ενός τέτοιου εργαλείου, συμπεριλαμβανομένης της ερμηνευσιμότητας, της γενίκευσης, της ηθικής και των τομέων για μελλοντική εργασία.

Κεφάλαιο 7ο: Συζήτηση και ηθικές απόψεις

Αυτό το κεφάλαιο εξετάζει τις επιπτώσεις των μεθόδων και των αποτελεσμάτων που περιγράφονται λεπτομερώς στα προηγούμενα κεφάλαια και τοποθετεί το σύστημα σε ένα ευρύτερο τεχνικό και ηθικό πλαίσιο. Η συζήτηση απεικονίζει την ερμηνεία της απόδοσης του μοντέλου και τις επιλογές κατωφλίου στην αξιολόγηση του κινδύνου δερματικών βλαβών, την ανθεκτικότητα της προτεινόμενης προσέγγισης και την πιθανή γενικευσιμότητα, τη δυνατότητα επηρεασμού της λήψης αποφάσεων και της συμπεριφοράς των χρηστών, καθώς και τις ηθικές και κανονιστικές παραμέτρους της ανάπτυξης ενός εργαλείου αξιολόγησης του κινδύνου δερματικών βλαβών σε συσκευές καταναλωτών. Το κεφάλαιο αυτό συνοψίζει τους περιορισμούς της διπλωματικής εργασίας όπως αναλύονται στις προηγούμενες ενότητες.

7.1 Ερμηνεία της απόδοσης και των επιλογών κατωφλίου

Τα αποτελέσματα της αξιολόγησης στο υποσύνολο επικύρωσης του HAM10000 δείχνουν ότι το μοντέλο είναι σε θέση να επιτύχει ένα αρκετά υψηλό επίπεδο διακριτικής απόδοσης στην δυαδική εργασία καλοήθους-κακοήθους, όπως υποδεικνύεται από την περιοχή κάτω από την καμπύλη ROC, και μια προσεκτική ερμηνεία μετρήσεων ευαισθησίας και ειδικότητας σε επιλεγμένα κατωφλια. Από μεθοδολογική άποψη, τα αποτελέσματα υποδεικνύουν ότι η επιλογή της αρχιτεκτονικής και των μεθοδολογιών εκπαίδευσης, συμπεριλαμβανομένης της μεταφοράς γνώσης από το ConVNeXt-Tiny, έχει δημιουργήσει επαρκείς αναπαραστάσεις μάθησης για δερματοσκοπικές εικόνες. Οι σύγχρονες μέθοδοι εστιάζουν στη συνεργασία μεταξύ ανθρώπων και μηχανών, με τους αλγόριθμους να χρησιμεύουν ως υποστηρικτικά εργαλεία στις κλινικές αποφάσεις, αντί να αντικαθιστούν αυτόνομα τη ιατρική κρίση [30].

Ταυτόχρονα, οι απόλυτες τιμές της ευαισθησίας, της ειδικότητας και της ακρίβειας πρέπει να αντιμετωπίζονται με προσοχή, καθώς αντανακλούν την απόδοση σε ένα μόνο σύνολο δεδομένων: περιορισμένο τόσο σε εύρος όσο και σε ποικιλία. Επιπλέον, ο ενθουσιασμός πρέπει να μετριαστεί, καθώς η αξιολόγηση έγινε σε ένα τμήμα επικύρωσης από το ίδιο υποκείμενο σύνολο δεδομένων με τα δεδομένα εκπαίδευσης, παρόλο που το σύνολο επικύρωσης ήταν διαχωρισμένο σε επίπεδο εικόνων από το σύνολο εκπαίδευσης. Ως εκ τούτου, η αναφερόμενη απόδοση δίνει μια ένδειξη ότι το μοντέλο γενικεύεται σε όλες τις βλάβες εντός του HAM10000, αλλά δεν εξασφαλίζει ανθεκτικότητα σε εικόνες που λαμβάνονται υπό πολύ διαφορετικές συνθήκες ή με πολύ διαφορετικές συσκευές.

Στο πλαίσιο αξιολόγησης κινδύνου μελανώματος, η επιλογή των κατωφλίων αντανακλά μια συνειδητή συνειδητή υπέρ της ευαισθησίας ώστε να ελαχιστοποιείται η πιθανότητα περιπτώσεων κακοήθους βλάβης. Οι ορισμοί των ζωνών χαμηλού, μεσαίου και υψηλού κινδύνου γενικεύουν αυτή την αντιστάθμιση σε μια τριμερή διαίρεση του εύρους των πιθανοτήτων. Η διαδικασία επιλογής κατωφλίου ενσωματώνει άμεσα έναν περιορισμό ασφάλειας στην αντιστοίχιση των πιθανοτήτων με τις κατηγορίες κινδύνου, περιορίζοντας το ποσοστό των κακοήθων περιπτώσεων στη ζώνη χαμηλού κινδύνου. Οι ζώνες που προκύπτουν θα έχουν διακριτές στατιστικές ιδιότητες στο σύνολο επικύρωσης. Η ζώνες κινδύνου επιτρέπουν τη μετάφραση της συνεχούς βαθμολογίας του μοντέλου σε ερμηνεύσιμες κατηγορίες, διευκολύνοντας την επικοινωνία αβεβαιότητας και του σχετικού κινδύνου. Αυτή η ανάλυση της επικοινωνίας των αποτελεσμάτων του μοντέλου στην εφαρμογή είναι εμφανής, ωστόσο είναι σημαντικό να σημειωθεί ότι οι αριθμητικές ιδιότητες των ζωνών προέρχονται από ένα συγκεκριμένο σύνολο δεδομένων και δεν ισχύουν απαραίτητα σε άλλους πληθυσμούς.

Η ερμηνεία των αποτελεσμάτων επικύρωσης για την προτεινόμενη προσέγγιση από ερμηνευτική άποψη οδηγεί στο συμπέρασμα ότι τα αποτελέσματα επιβεβαιώνουν την τεχνική συνέπεια της προτεινόμενης προσέγγισης όσον αφορά την ικανότητα του μοντέλου να αναγνωρίζει κακοήθεις έναντι καλοήθων βλαβών. Για παράδειγμα, η μεγάλη περιοχή κάτω από την καμπύλη ROC (AUC) που προέκυψε από το υποσύνολο επικύρωσης HAM10000 υποδεικνύει ότι το μοντέλο έχει δείξει την ικανότητα να

κατατάσσει γενικά τον σχετικό βαθμό κακοήθειας των βλαβών που σχετίζονται με καλοήθεις και κακοήθεις καταστάσεις αντίστοιχα, αλλά αυτό δεν σημαίνει απαραίτητα ότι το μοντέλο θα παράγει πάντα έναν απολύτως ακριβή διαχωρισμό των δύο κατηγοριών βλαβών. Οι καλοήθεις βλάβες ενδέχεται να λάβουν μια σχετικά υψηλή πιθανότητα κακοήθειας από το μοντέλο, ενώ οι κακοήθεις βλάβες θα έχουν μια σχετικά χαμηλότερες πιθανότητες κακοήθειας από το μοντέλο. Οι αναλύσεις ευαισθησίας και ειδικότητας που διεξήχθησαν στο Κεφάλαιο 5 της παρούσας διατριβής έχουν αποδείξει ρητά τη συμβιβαστική λύση μεταξύ αυτών των μέτρων σε ένα εύρος ορίων απόφασης που αξιολογήθηκαν κατά τη διάρκεια της ανάλυσης επιλογής ορίου.

Ενώ το αποτέλεσμα του μοντέλου σε οποιοδήποτε δεδομένο χρονικό σημείο αντιπροσωπεύει μια διαγνωστική πιθανότητα και όχι μια διαγνωστική βεβαιότητα, είναι πολύ πιο χρήσιμο να ερμηνεύεται το αποτέλεσμα του μοντέλου ως μια συνεχής βαθμολογία κινδύνου, η οποία μπορεί στη συνέχεια να χωριστεί κατηγορηματικά σε ζώνες κινδύνου σε σχέση με τον χαμηλό, μέτριο και υψηλό κίνδυνο. Η απόφαση να επιβληθεί ένα περιθώριο ασφαλείας στη ζώνη χαμηλού κινδύνου, περιορίζοντας το ποσοστό των κακοήθων βλαβών που περιέχονται στη ζώνη χαμηλού κινδύνου, είναι, στην ουσία, μια συντηρητική προσέγγιση ως προς την ταξινόμηση του κινδύνου. Θα ήταν πιο συμφέρουσα η απόδοση μέτριου ή μεγαλύτερου κινδύνου σε ορισμένες καλοήθεις βλάβες παρά η απόδοση χαμηλού κινδύνου σε σημαντικό αριθμό κακοήθων βλαβών. Ωστόσο, εκτός από την άσκηση προσοχής, η ανάλυση επιλογής κατωφλίου προσπάθησε να μεγιστοποιήσει τη χρησιμότητα της ζώνης χαμηλού κινδύνου, συμπεριλαμβάνοντας όσο το δυνατόν περισσότερες σαφώς καλοήθεις βλάβες εντός των παραμέτρων που επιτρέπονται από ένα περιθώριο ασφαλείας. Η ανάγκη εξισορρόπησης μεταξύ της ανάγκης για καθυσύχαση των ασθενών και της ανάγκης για συντηρητικές ταξινομήσεις κινδύνου είναι πρωταρχικής σημασίας όσον αφορά την ερμηνεία και την κατανόηση της αναφερόμενης απόδοσης ακρίβειας.

Μια άλλη σημαντική ερμηνευτική παράμετρος είναι ότι όλες οι μετρήσεις απόδοσης που αναφέρονται για την αξιολόγηση του μοντέλου έχουν καθοριστεί χρησιμοποιώντας ένα σύνολο επικύρωσης που προέρχεται από το HAM10000, ένα καθιερωμένο αλλά σχετικά μικρό σύνολο δεδομένων δερματοσκοπικών εικόνων. Όπως τονίζεται αλλού σε αυτή τη διατριβή, τα στατιστικά χαρακτηριστικά των ζωνών κινδύνου του μοντέλου (το ποσοστό των κακοήθων βλαβών σε κάθε ζώνη κινδύνου) καθορίζονται σε σχέση με το σύνολο δεδομένων από το οποίο δημιουργήθηκαν και δεν μπορεί να θεωρηθεί ότι έχουν τις ίδιες στατιστικές και πληθυσμιακές ιδιότητες όταν εξετάζονται διαφορετικοί πληθυσμοί ασθενών και συνθήκες λήψης εικόνων. Επομένως, τα αποτελέσματα της επικύρωσης του μοντέλου δεν πρέπει να θεωρούνται ως μια καθολική εγγύηση απόδοσης για το πλήρες φάσμα των περιπτώσεων που θα παρουσιαστούν στην κλινική πρακτική. Αντίθετα, τα αποτελέσματα της επικύρωσης πρέπει να θεωρούνται ως μια αναπαράσταση της ικανότητας του μοντέλου να διακρίνει μεταξύ περιπτώσεων εντός ενός συγκεκριμένου συνόλου δεδομένων.

Η αξιολόγηση υπογράμμισε επίσης τη διαφορά μεταξύ διάκρισης και βαθμονόμησης. Η διάκριση είναι η ικανότητα του μοντέλου να διαχωρίζει τις κακοήθεις από τις καλοήθεις βλάβες, όπως μετράται με μετρήσεις όπως το AUC και η θετική και αρνητική προγνωστική αξία που υπολογίζονται σε επιλεγμένα κατώφλια. Αντίθετα, η βαθμονόμηση είναι ο βαθμός στον οποίο οι προβλεπόμενες πιθανότητες αντικατοπτρίζουν την πραγματική συχνότητα εμφάνισης κακοήθειας μεταξύ των ασθενών για τους οποίους ορίστηκαν οι ζώνες κινδύνου, και ενώ στην παρούσα εργασία η βαθμονόμηση συζητείται μόνο ποιοτικά σε περιορισμένο βαθμό, η βαθμονόμηση θα εξεταστεί περαιτέρω σε μελλοντικές βελτιώσεις του συστήματος. Τέλος, καθώς αυτή η εφαρμογή αντιπροσωπεύει την κατηγοριοποίηση του κινδύνου και όχι τις ακριβείς προβλεπόμενες πιθανότητες, δεν θα υπάρχει απαραίτητα τέλεια αντιστοιχία μεταξύ πιθανότητας και ζώνης κινδύνου, αν και πολλά μπορούν να εξάγονται σχετικά με αυτή τη σχέση από την παρατηρούμενη κατανομή των αποτελεσμάτων από το σύνολο δεδομένων επικύρωσης. Επομένως, απαιτείται η διερεύνηση και βελτίωση της βαθμονόμησης πριν από οποιαδήποτε ευρύτερη πρακτική εφαρμογή του συστήματος.

7.2 Ανθεκτικότητα και γενικευσιμότητα

Ένα βασικό ζήτημα σε οποιοδήποτε σύστημα που βασίζεται σε δεδομένα είναι ο βαθμός στον οποίο μπορεί κανείς να αναμένει ότι η συμπεριφορά του συστήματος θα γενικευτεί πέρα από τα δεδομένα με τα οποία εκπαιδεύτηκε και επικυρώθηκε. Σε αυτήν την περίπτωση, τα δεδομένα εκπαίδευσης και αξιολόγησης είναι εξ ολοκλήρου δερματοσκοπικές εικόνες από το HAM10000 και το προβλεπόμενο πλαίσιο εφαρμογής είναι μια εφαρμογή για κινητά, όπου ο τελικός χρήστης λαμβάνει εικόνες με ένα smartphone καταναλωτή. Η μεταβολή τομέα μεταξύ κλινικών και μη κλινικών δεδομένων αποτελεί μια σημαντική πρόκληση για την ικανότητα γενίκευσης των μοντέλων βαθιάς μάθησης στην ιατρική απεικόνιση [28]. Αν και υπάρχει μια διεπαφή περικοπής στην εφαρμογή και ένας έλεγχος ποιότητας εικόνας που θα μετατοπίσει την κατανομή εισόδου κάπως πιο κοντά στις δερματοσκοπικές εικόνες, η μετατόπιση του τομέα παραμένει μεγάλη.

Ο σκοπός της χρήσης ισχυρής επαύξησης δεδομένων κατά τη διάρκεια της εκπαίδευσης είναι να μειωθεί η ευαισθησία του μοντέλου στη μετατόπιση του τομέα. Η διαδικασία επαύξησης δεδομένων περιλαμβάνει τυχαίες περιστροφές, τυχαίες ανατροπές, τυχαία ρύθμιση της φωτεινότητας και της αντίθεσης, προσομοιωμένη θολούρα, προσθήκη συμπίεσης όπως τεχνητά στοιχεία και συνθετικά μαλλιά. Με την παρουσίαση του μοντέλου σε αυτές τις μετατοπίσεις κατά τη διάρκεια της εκπαίδευσης, είναι πιο πιθανό να ανεχθεί τέτοιες διαταραχές στην πράξη. Ωστόσο, αυτές οι μετασχηματισμοί δεν μπορούν ποτέ να αντικαταστήσουν την πραγματική ποικιλομορφία των δεδομένων εκπαίδευσης. Οι πραγματικές φωτογραφίες από smartphone μπορεί να διαφέρουν με τρόπους που δεν αντιμετωπίζονται από τη διαδικασία επαύξησης, συμπεριλαμβανομένων διαφορών στον φωτισμό, την ακρίβεια των χρωμάτων, την οπτική της συσκευής, τους τόνους του δέρματος, το περιβάλλον της βλάβης και την ακαταστασία του φόντου. Επομένως, η απόδοση που παρατηρήθηκε στο HAM10000 δεν πρέπει να ερμηνευθεί ως διατηρημένη και αμετάβλητη στις εικόνες που συλλέχθηκαν από την καθημερινή χρήση.

Γενικευμένες ερωτήσεις προκύπτουν επίσης σε σχέση με τα χαρακτηριστικά του πληθυσμού των ασθενών και τους τύπους των βλαβών. Η σύνθεση του HAM10000 αντικατοπτρίζει ορισμένες συγκεκριμένες κλινικές πηγές ωστόσο δεν είναι σαφές εάν καταγραφεί επαρκώς το φάσμα των τύπων δέρματος, των ηλικιών ή των περιοχών διαμονής. Εάν οι ασθενείς αξιολογούνται με το σύστημα και τα δημογραφικά στοιχεία διαφέρουν σημαντικά από αυτά που εκπροσωπούνται στην εκπαίδευση, η απόδοση μπορεί να ποικίλλει σε διαφορετικές υποομάδες. Πρόσφατες μελέτες σχετικά με τα συστήματα ανάλυσης δέρματος έχουν τραβήξει την προσοχή στην ανάγκη αξιολόγησης της απόδοσης τους σε ποικιλία τύπων δέρματος και δημογραφικών ομάδων, ώστε να ελαχιστοποιούνται οι συστηματικές αποκλίσεις και οι προκαταλήψεις [29]. Οποιαδήποτε διακύμανση στην απόδοση μπορεί να εγείρει ζητήματα δικαιοσύνης και ισότητας στην αξιόπιστη αξιολόγηση του κινδύνου. Η επισήμανση αυτών των κενών θα απαιτούσε ένα ευρύτερο φάσμα συνόλων δεδομένων και μια πιο στρωματοποιημένη αναλυτική προσέγγιση σε δημογραφικούς και κλινικούς παράγοντες που μπορεί να είναι σχετικοί. Ως αποτέλεσμα, το μοντέλο και τα αποτελέσματά του σε αυτή τη διατριβή θα πρέπει να θεωρηθούν ως απόδειξη σκοπιμότητας που προέρχεται από ένα κοινώς χρησιμοποιούμενο σύνολο δεδομένων δερματοσκοπίας, και όχι ως μια αποδεκτή λύση για πρακτική εφαρμογή σε όλα τα πλαίσια.

Η μετατόπιση του τομέα διαχωρίζει τους τύπους δεδομένων που χρησιμοποιούνται για την εκπαίδευση του μοντέλου μηχανικής μάθησης και το περιβάλλον στο οποίο θα χρησιμοποιηθεί τελικά. Συγκεκριμένα, τα δεδομένα εκπαίδευσης και τα δεδομένα επικύρωσης είναι εικόνες που λαμβάνονται με τη χρήση εξοπλισμού δερματοσκόπησης σε ελεγχόμενο περιβάλλον, ενώ το περιβάλλον ανάπτυξης θα αποτελείται από εικόνες που λαμβάνονται από χρήστες με τη χρήση των κινητών τους τηλεφώνων, χωρίς εξειδικευμένο ή ελεγχόμενο περιβάλλον και ενδεχομένως σε συνθήκες κακού φωτισμού, σε γωνίες που δεν είναι κάθετες προς το αντικείμενο ή με ολική ή μερική απόκρυψη του αντικειμένου.

Η διαδικασία επαύξησης και οι έλεγχοι ποιότητας εικόνας που δημιουργήθηκαν στα προηγούμενα κεφάλαια μπορούν να συμβάλουν στη μείωση των επιπτώσεων της μετατόπισης τομέα, αλλά δεν μπορούν να εξαλείψουν πλήρως την επίδραση. Επομένως, οποιαδήποτε απόδοση επιτυγχάνεται με το

σύνολο δεδομένων HAM10000 πρέπει να ερμηνεύεται ως αισιόδοξη εκτίμηση και είναι πολύ πιθανό ότι η απόδοση στην πράξη θα είναι χειρότερη, ιδίως για εικόνες που διαφέρουν σημαντικά από αυτές που χρησιμοποιήθηκαν για τη δημιουργία του συνόλου δεδομένων εκπαίδευσης.

Εκτός από αυτή την χρονική μεταβολή των δεδομένων και του τεχνολογικού περιβάλλοντος, υπάρχουν και άλλοι παράμετροι που πρέπει να ληφθούν υπόψη όσον αφορά την ανθεκτικότητα του μοντέλου: η χρήση των καμερών των smartphone, ο τρόπος ανάπτυξης των λειτουργικών συστημάτων και η συμπεριφορά των χρηστών με τα smartphone θα εξελιχθούν με την πάροδο του χρόνου. Επιπλέον, η εμφάνιση και η παρουσίαση των δερματικών παθήσεων σε διαφορετικούς πληθυσμούς θα εξελιχθούν επίσης με την πάροδο του χρόνου. Ως εκ τούτου, η ικανότητα ενός μοντέλου που αναπτύχθηκε από ένα στατικό σύνολο δεδομένων να προσαρμοστεί στις αλλαγές με την πάροδο του χρόνου είναι περιορισμένη. Κατ' αρχήν, η βελτίωση της ανθεκτικότητας θα μπορούσε να επιτευχθεί με την ενημέρωση του μοντέλου μέσω περιοδικής επανεκπαίδευσης ή βελτιστοποίησης νέων δεδομένων, με τη χρήση πιο ποικίλων πηγών δεδομένων ή με τη διεξαγωγή ρητών διαδικασιών προσαρμογής του τομέα. Ωστόσο, τέτοιες προσεγγίσεις εισάγουν πρόσθετες πολυπλοκότητες όσον αφορά την ανάγκη για συνεχή και ενημερωμένη κλινική επικύρωση, συνεχή παρακολούθηση της απόδοσης του μοντέλου μεταξύ υποπληθυσμών και προσεκτική διαχείριση όλων των δεδομένων που συλλέγονται από τους χρήστες. Για το σκοπό αυτό, οι εργασίες αυτές δεν εμπίπτουν στο πεδίο εφαρμογής της παρούσας διατριβής, αλλά υπογραμμίζουν τη συνεχή διαδικασία ανάπτυξης βελτιωμένης ανθεκτικότητας αντί της επίτευξης ενός μεμονωμένου σημείου στο χρόνο.

Επιπλέον, η δικαιοσύνη και η αντιπροσωπευτικότητα ενός δημόσιου συνόλου δεδομένων δερματοσκοπίας θα περιορίσει σε μεγάλο βαθμό ορισμένες ομάδες τύπων δέρματος, ηλικιακών ομάδων και ανατομικών θέσεων, οι οποίες είναι κατηγορίες που έχουν βρεθεί να είναι υποεκπροσωπούμενες. Επομένως, εάν η μηχανική μάθηση ανέπτυξε όρια λήψης αποφάσεων για την πλειονότητα των περιπτώσεων που βρέθηκαν στο HAM10000, έχετε λιγότερη ακρίβεια από ό,τι για τους υποεκπροσωπούμενους πληθυσμούς. Ως εκ τούτου, η χρήση αυτού του μοντέλου ως γενικού εργαλείου θα διαδώσει τις υπάρχουσες ανισότητες στην ανίχνευση του καρκίνου του δέρματος. Μια ολοκληρωμένη αξιολόγηση τέτοιων επιδράσεων θα απαιτούσε στρωματοποιημένα σύνολα δεδομένων και εξαντλητικά δημογραφικά δεδομένα. Επομένως, η παρούσα διατριβή παρουσιάζει το μοντέλο ως πειραματική προσέγγιση με βάση ένα σύνολο δεδομένων δερματοσκοπίας και όχι ως ολοκληρωμένη λύση. Επομένως, δεν προορίζεται να αποτελέσει μια ολοκληρωμένη λύση για κάθε δημογραφικό και κλινικό σενάριο.

Παρά τις προειδοποιήσεις αυτές, τα πέντε πρώτα κεφάλαια της μελέτης περιγράφουν λεπτομερώς τα διαστήματα λήψης αποφάσεων, εισάγουν μια ζώνη ενδιάμεσου κινδύνου και χρησιμοποιούν αυστηρές δηλώσεις αποποίησης ευθύνης για να αυξήσουν την αντοχή του μοντέλου στην αναπόφευκτη υποβάθμιση της γενίκευσης που θα προκύψει κατά τη μετάβαση από δερματοσκοπικές εικόνες σε φωτογραφίες κινητών τηλεφώνων που υποβάλλονται από χρήστες. Αντί να παρουσιάζει το μοντέλο ως οριστική πηγή διάγνωσης, η μελέτη το παρουσιάζει ως προσωρινό βοήθημα που ενθαρρύνει τη σύνδεση με την επαγγελματική κλινική αξιολόγηση όταν μια βλάβη αποτελεί σημαντικό λόγο ανησυχίας. Οριστικές απαντήσεις μπορούν να δοθούν μόνο μέσω της κλινικής εξέτασης και, ενδεχομένως, μέσω των διαδικασιών ιστοπαθολογίας.

7.3 Ηθικές σκέψεις, περιορισμοί και συμπεράσματα

Η δημιουργία ενός συστήματος που λαμβάνει εικόνες των βλαβών στο δέρμα και εμφανίζει πληροφορίες σχετικά με τον κίνδυνο παρουσιάζει ένα σύνολο από πιθανά ηθικά και πρακτικά ζητήματα που θέτουν περιορισμούς στον τρόπο με τον οποίο μπορούν να ερμηνευθούν τα δεδομένα. Πρώτον, φαίνεται να υπάρχει πιθανότητα βλάβης που σχετίζεται με ψευδή διαβεβαίωση. Πάρα τον καθορισμό των ζωνών κινδύνου για την μείωση του ποσοστού των κακοήθων βλαβών στην κατηγορία χαμηλού

κίνδυνου, ορισμένες βλάβες θα καταχωθούν εκεί αναπόφευκτα. Εάν αυτό το αποτέλεσμα παρερμηνευθεί ως διαβεβαίωση για την παραίτηση από οποιαδήποτε ιατρική παρακολούθηση, το χρονικό πλαίσιο για τη διάγνωση και τη θεραπεία καθυστερεί. Από την άλλη πλευρά, ο σχεδιασμός ευνόησε την υψηλή ευαισθησία, η οποία θα παράγει ένα σημαντικό αριθμό ψευδών θετικών αποτελεσμάτων, ιδίως στη ζώνη υψηλού κινδύνου, με ελάχιστη ανησυχία για περιττές ανησυχίες και ακόμη λιγότερη προσοχή στην επίδραση στην τελική ζήτηση κλινικής αξιολόγησης. Επομένως, η επιλογή των σημείων λειτουργίας συνεπάγεται ηθικές θέσεις πέραν της στατιστικής βάσης που εμπλέκεται και εξαρτάται από το σκεπτικό του πόσο ανεκτά είναι τα ψευδώς θετικά αποτελέσματα για τη μείωση της πιθανότητας παράλειψης κακοήθειας.

Τα ρυθμιστικά και τα θέματα απορρήτου εισάγουν περιορισμούς. Διάφορες επιστημονικές οργανώσεις και επιτροπές έχουν αρχίσει να συντάσσουν κατευθυντήριες γραμμές για την ανάπτυξη, αξιολόγηση και κλινική ενσωμάτωση αλγορίθμων τεχνητής νοημοσύνης στο χώρο της δερματολογίας [31]. Το λογισμικό που επεξεργάζεται ιατρικές εικόνες και παρέχει ευκαιρίες για διαγνωστικές ή θεραπευτικές συστάσεις μπορεί να εμπίπτει στο πλαίσιο εποπτείας των κανονισμών για τα ιατρικά βοηθήματα, το οποίο θα απαιτεί επίσημους κώδικες αξιολόγησης και πιστοποίησης. Σε αυτή τη διατριβή, το σύστημα ορίζεται ως ερευνητικό πρωτότυπο και ως εργαλείο γνώσης και όχι ως εργαλείο υποστήριξης διαγνωστικών αποφάσεων. Από την άποψη της ιδιωτικής ζωής, η εκτέλεση συμπερασμάτων αποκλειστικά στη συσκευή μετριάξει τις ανησυχίες σχετικά με την έκθεση ευαίσθητων δεδομένων εικόνων, αλλά δεν τις εξαλείφει εντελώς, αναφέροντας ανησυχίες σχετικά με την τοπική αποθήκευση, την ασφάλεια της συσκευής και την πιθανή επαναχρησιμοποίηση των δεδομένων κατά τη διάρκεια της διόρθωσης σφαλμάτων ή της έρευνας.

Ο κίνδυνος ψευδούς διαβεβαίωσης αποτελεί σημαντικό ηθικό ζήτημα σε σχέση με αυτό το έργο. Ακόμη και με συντηρητικά όρια και πρότυπα ασφαλείας, ορισμένες κακοήθειες βλάβες θα καταταχθούν αναπόφευκτα στην κατηγορία χαμηλού κινδύνου. Εάν ένας χρήστης πιστεύει ότι ένα μήνυμα χαμηλού κινδύνου σημαίνει «όλα εντάξει», ενδέχεται να καθυστερήσει την αναζήτηση ιατρικής περίθαλψης. Αυτό θέτει τους χρήστες σε κίνδυνο, ακόμη και σε περιπτώσεις όπου τα πραγματικά περιστατικά είναι λίγα. Επομένως, η διατύπωση των μηνυμάτων κινδύνου και η διεπαφή αυτού του συστήματος θα υπενθυμίζουν συνεχώς στους χρήστες να παραμένουν σε εγρήγορση: όλα τα αποτελέσματα χαμηλού κινδύνου θα κοινοποιούνται ως «προφανώς χαμηλού κινδύνου με βάση τα αποτελέσματα του μοντέλου, αλλά όχι ως διάγνωση», και οι χρήστες θα πρέπει να αναζητούν ιατρό για οποιαδήποτε αξιοσημείωτη αλλαγή ή συνεχιζόμενη ανησυχία. Η ιδέα είναι να παρουσιαστεί αυτό το σύστημα ως ένα εργαλείο υποστήριξης που βοηθά τους χρήστες να γνωρίζουν πότε είναι σκόπιμο να ζητήσουν τη συμβουλή του γιατρού τους και όχι να αντικαταστήσει τις ανάγκες του ιατρού.

Ωστόσο, η υπερβολικά συντηρητική προσέγγιση μπορεί να είναι επιζήμια. Εάν τα όρια είχαν ρυθμιστεί έτσι ώστε πολλές κακοήθειες βλάβες να ταξινομούνται ως μέτριου ή υψηλού κινδύνου, θα υπήρχε μεγαλύτερη πιθανότητα να δημιουργηθούν ψευδείς συναγερμοί από την εφαρμογή, και η προκύπτουσα ανησυχία θα προκαλούσε πιθανώς περιττές επισκέψεις σε δερματολόγους. Αυτό δημιουργεί οικονομικό βάρος τόσο για τους χρήστες του συστήματος όσο και για τα συστήματα υγειονομικής περίθαλψης. Η διαδικασία επιλογής των ορίων προσπαθεί να εξισορροπήσει τα άκρα της διατήρησης ενός πολύ χαμηλού ποσοστού κακοήθων βλαβών στη ζώνη χαμηλού κινδύνου με την εξασφάλιση ενός σημαντικού ποσοστού οριστικά καλοήθων βλαβών. Αυτή η συμβιβαστική λύση δεν είναι απόλυτη και εξαρτάται σε μεγάλο βαθμό από το σύνολο δεδομένων που χρησιμοποιείται. Ωστόσο, καθιστώντας την ορατή, εξαλείφεται η ψευδαίσθηση ότι η ασφάλεια και η χρησιμότητα μπορούν να βελτιστοποιηθούν ανεξάρτητα.

Η προστασία των δεδομένων και η ιδιωτικότητα είναι επίσης σημαντικοί παράγοντες σε όλα τα συστήματα που αναλύουν ιατρικές εικόνες πέρα από τη λειτουργία επικοινωνίας κινδύνου. Όλες οι αναλύσεις στο σχέδιο που παρουσιάζεται σε αυτή τη διατριβή πραγματοποιούνται στην συσκευή με το μοντέλο TensorFlow Lite στην εφαρμογή για κινητά και όλες οι εικόνες υποβάλλονται σε επεξεργασία στο smartphone του χρήστη αντί να μεταφορτώνονται σε εξωτερικό διακομιστή ή Cloud. Αυτό σημαίνει

ότι δεν δημιουργείται κύρια βάση δεδομένων με εικόνες των χρηστών και οι παραβάσεις συμμόρφωσης δεν δημιουργούν πρόσθετη κανονιστική πολυπλοκότητα και μειώνουν τον κίνδυνο μη εξουσιοδοτημένης πρόσβασης στα δεδομένα. Ενώ η επεξεργασία στη συσκευή θα πρέπει να επιτρέπει στον χρήστη να κατανοήσει τι θα αποθηκεύσει η εφαρμογή και πώς θα το χρησιμοποιήσει, θα πρέπει να υπάρχουν σαφείς εξηγήσεις προς τους χρήστες σχετικά με το τι ακριβώς θα αποθηκεύσει η εφαρμογή και πώς θα επεξεργαστεί τα αρχεία, μαζί με την τήρηση βέλτιστων πρακτικών για την ασφάλεια σε επίπεδο πλατφόρμας για τη διαχείριση αρχείων και την προσωρινή αποθήκευση δεδομένων.

Τέλος, η διατριβή μας υπενθυμίζει ότι δεν πρέπει να παραπλανήστε ο χρήστης χαρακτηρίζοντας την εφαρμογή ως διαγνωστικό εργαλείο. Ως εκ τούτου, το σύστημα θεωρείται σταθερά ως εργαλείο πληροφόρησης ή «υποστήριξης λήψης αποφάσεων»· μπορεί να βοηθήσει τους χρήστες να εντοπίσουν βλάβες που θα πρέπει να αξιολογηθούν από γιατρό και να τους επιτρέψει να λάβουν επαγγελματική συμβουλή σε πιο έγκαιρο χρόνο από ό,τι θα συνέβαινε διαφορετικά. Αυτή η άποψη για το εργαλείο συνάδει με την τρέχουσα βιβλιογραφία σχετικά με την ηθική της τεχνητής νοημοσύνης στην υγειονομική περίθαλψη, η οποία προάγει τη διαφάνεια των δυνατοτήτων και των περιορισμών, τις ρεαλιστικές προσδοκίες και τη συνεκτίμηση του ρόλου των επαγγελματιών.

Υπάρχουν αρκετοί περιορισμοί της εργασίας που αξίζει να διερευνηθούν περαιτέρω. Πρώτον, το μοντέλο εκπαιδεύτηκε και δοκιμάστηκε σε ένα μόνο σύνολο δεδομένων δερματοσκοπίας. Δεν έχει επικυρωθεί προοπτικά με βάση την πραγματική χρήση smartphone. Δεύτερον, οι αναλύσεις ολοκληρώθηκαν χρησιμοποιώντας μεθόδους αξιολόγησης εκτός σύνδεσης και αναδρομικά όρια. Δεν υπάρχουν ευρήματα από μελέτες χρηστών που θα μπορούσαν να ρίξουν φως στον τρόπο με τον οποίο τα άτομα ανταποκρίνονται στα μηνύματα που μεταδίδει η εφαρμογή. Τρίτον, ενώ οι ηθικές πτυχές συζητήθηκαν εννοιολογικά, βασιζόμενες στη βιβλιογραφία και στις σκέψεις του συγγραφέα, δεν είχαν εμπειρική βάση (συμπεριφορές χρηστών και κλινικά αποτελέσματα). Επομένως, η εργασία πρέπει να θεωρηθεί κυρίως ως τεχνική και σχεδιαστική διερεύνηση και όχι ως τελικό ιατρικό βοήθημα.


Το έργο αυτό παρουσιάζει μια προσέγγιση ενσωμάτωσης της τεχνολογία βαθιάς μάθησης στην ανάλυση δερματικών βλαβών σε ένα ευρύτερο κοινωνικό και τεχνικό πλαίσιο. Η διαδικασία επιλογής μιας αρχιτεκτονικής, η εκπαίδευσή της και η αναφορά μιας τιμής AUC είναι μόνο ένα μέρος ενός πολύ ευρύτερου πλαισίου. Επιπλέον, οι επαγγελματίες πρέπει να αφιερώσουν ίση προσοχή στην επιλογή ορίων για το μοντέλο, στην αποτελεσματική επικοινωνία των κινδύνων, στον κατάλληλο σχεδιασμό της διεπαφής χρήστη και στην ηθική διαμόρφωση της τεχνολογίας. Τα συμπεράσματα αυτού του κεφαλαίου έχουν δύο ρόλους: παρέχουν το πλαίσιο για τα συγκεκριμένα αποτελέσματα που παρουσιάστηκαν στα προηγούμενα κεφάλαια και προσφέρουν γενικές αρχές για τον υπεύθυνο σχεδιασμό και την ερμηνεία παρόμοιων συστημάτων. Το τελευταίο κεφάλαιο βασίζεται σε αυτές τις αρχές προκειμένου να συνοψίσει τις βασικές συνεισφορές της διατριβής και να παρουσιάσει κατευθύνσεις για μελλοντική έρευνα με σκοπό την αντιμετώπιση ορισμένων περιορισμών και ηθικών ζητημάτων που θα προκύψουν.

Κεφάλαιο 8ο: Παραδείγματα και επεξήγηση χρήσης εφαρμογής


8.1 Επεξήγηση

Στην περίπτωση αυτή ο χρήστης στέλνει ή ανεβάζει από την συλλογή μια καθαρή φωτογραφία με αρκετό φωτισμό δείχνοντας το μέρος που θέλει να εκλεχθεί

Αρχική Σελίδα



Επιλογή φωτογραφίας

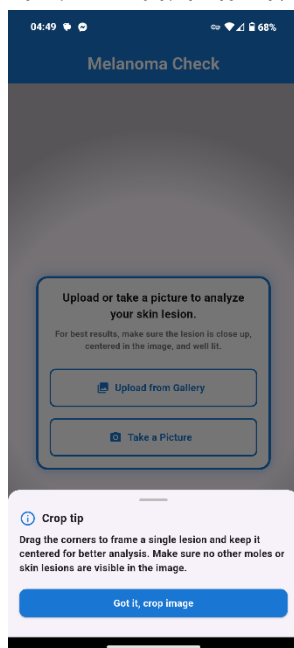


Λήψη φωτογραφίας



Υστερα ο χρήστης παίρνει ένα μήνυμα που τον παροτρύνει να περικόψει το αποτέλεσμα έτσι ώστε η φωτογραφία που στέλνει στο αι να είναι κατάλληλη και χωρίς να φαίνονται περιττά πράγματα που μπορεί να επηρεάσουν το αποτέλεσμα. Στο επόμενο βήμα γίνεται περικοπή της εικόνας.

Μήνυμα επεξήγησης λήψης



Διαδικασία περικοπής εικόνας

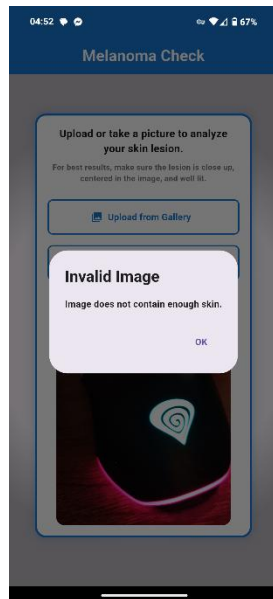


Αφότου ολοκληρωθεί η διαδικασία περικοπής, η εικόνα περνάει από ελέγχους πρώτου περάσει από το αι. Οι έλεγχοι αυτοί αφορούν την καθαρή εικόνα και το αν η φωτογραφία περιλαμβάνει δέρμα ή όχι.

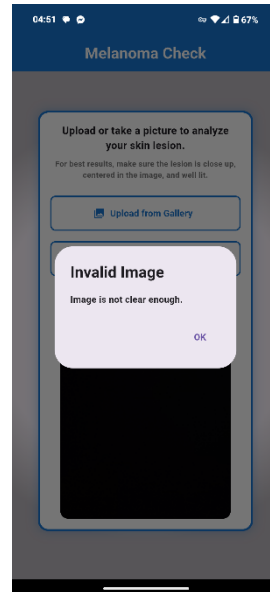
Παραδείγματα και επεξήγηση χρήσης εφαρμογής

Στην συνέχεια ακολουθούν αυτές οι δυο περιπτώσεις:

Εικόνα που δεν περιέχει δέρμα




Εικόνα χωρίς καθαρή λήψη




Αφού περάσει από τους ελέγχους, το επόμενο βήμα είναι το αι δίνοντας την πιθανότητα μελανώματος.

Αποτέλεσμα πιθανότητας μελανώματος



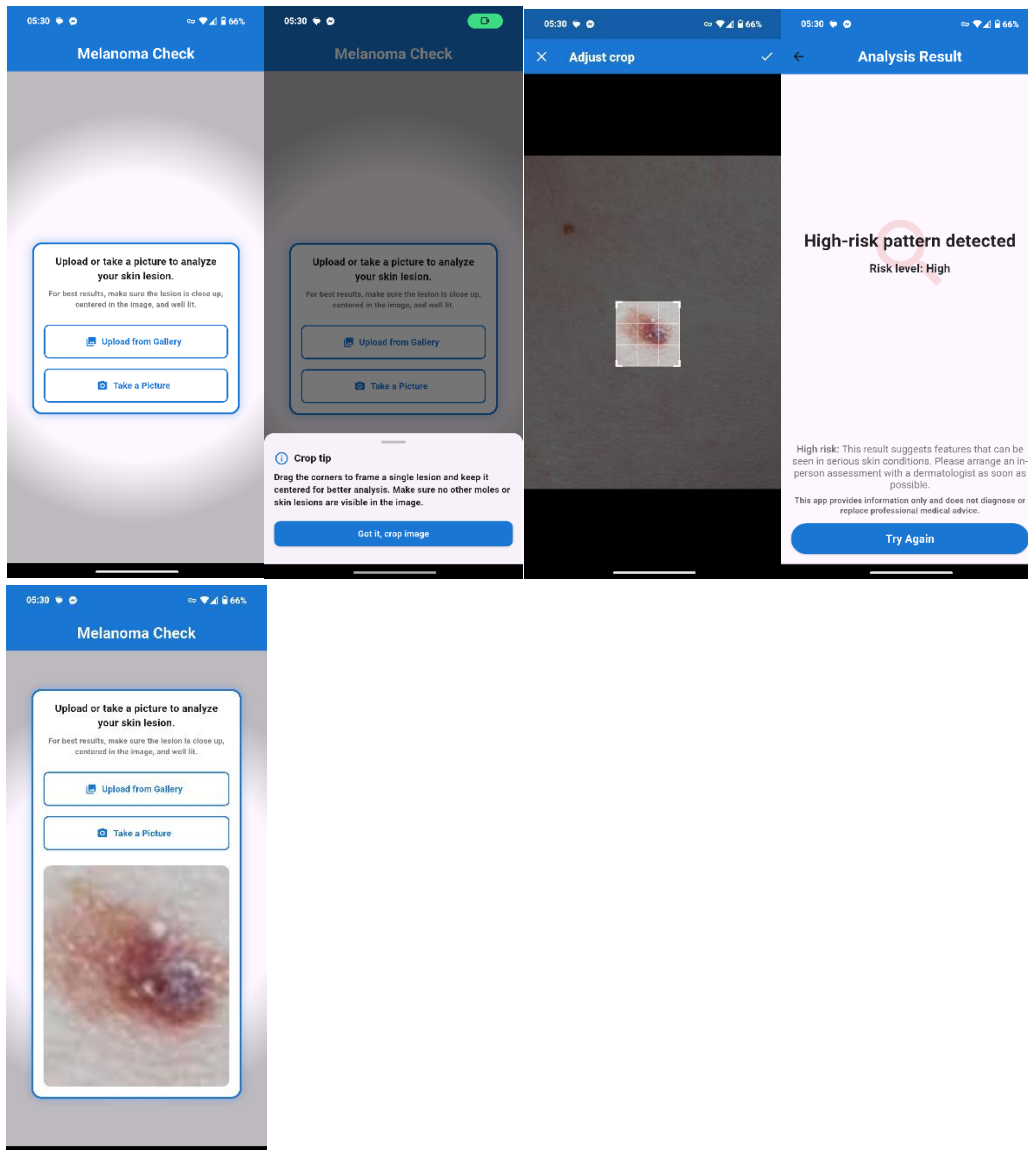
Τα επιπλέον κουμπιά στην τελική οθόνη κάνουν τα παρακάτω:

Το κουμπί Try Again οδηγεί το χρήστη στην αρχική οθόνη ενώ το πίσω βέλος του δείχνει την αρχική καθώς και την φωτογραφία που έχει ανεβάσει.



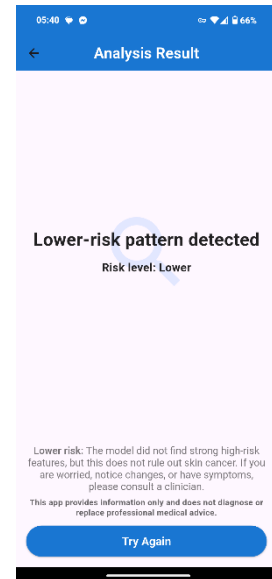
8.2 Παράδειγμα υψηλής επικινδυνότητας

Ακολουθεί παρακάτω παράδειγμα εκ του οποίου ο χρήστης στέλνει φωτογραφία μελανώματος.



8.3 Παράδειγμα χαμηλής επικινδυνότητας

Ακολουθεί παράδειγμα όπου ο χρήστης στέλνει φωτογραφία μιας ελιάς ή σημάδι εκ γενετής.



Κεφάλαιο 9ο: Συμπέρασμα και μελλοντικές εργασίες

Αυτό το κεφάλαιο συνοψίζει τις βασικές συνεισφορές αυτής της διπλωματικής και επιδιώκει να καθορίσει ορισμένες από τις κατευθύνσεις που μπορούν να ακολουθηθούν για περαιτέρω έρευνα και ανάπτυξη. Αυτή η εργασία διερεύνησε το σχεδιασμό, την εκπαίδευση και την ανάπτυξη ενός μοντέλου βαθιάς μάθησης για την ταξινόμηση καλοήθων-κακοήθων χρωστικών δερματικών βλαβών και ενσωμάτωσε αυτό το μοντέλο σε μια εφαρμογή για κινητά που παρέχει ενδείξεις κινδύνου υπό εξηγήσιμους περιορισμούς ασφαλείας.

9.1 Συμπέρασμα

Η διπλωματική εργασία έδειξε μια ολοκληρωμένη διαδικασία κατά την οποία τα δεδομένα ρέουν από ένα αρχείο δερματοσκοπικών εικόνων σε ένα εργαλείο ένδειξης κινδύνου στο οποίο μπορεί να έχει πρόσβαση ο χρήστης μέσω κινητής συσκευής. Η διαδικασία δεδομένων ξεκινά με το σύνολο δεδομένων HAM10000, το οποίο φιλτράρεται για να περιλαμβάνει έγκυρες εικόνες, ακολουθούμενο από μια καθοριστική αντιστοίχιση διαγνωστικών κατηγοριών για να σχηματιστεί εάν δυαδικό πρόβλημα καλοήθους-κακοήθους. Ορίζεται μια στρωματοποιημένη διαίρεση εκπαίδευσης-επικύρωσης για τη διατήρηση των αναλογιών των κατηγοριών και ορίζεται μια ροή προ-επεξεργασίας που κεντράρει τις εικόνες σε ένα τετράγωνο και τις αναδιαμορφώνει σε μια σταθερή ανάλυση που είναι συμβατή με την είσοδο του μοντέλου. Σημειωτέον ότι η κωδικοποιημένη αύξηση δεδομένων και οι στρατηγικές για την αντιμετώπιση της ανισορροπίας των κατηγοριών (γεωμετρικές και φωτομετρικές μετασχηματισμοί, προσομοιωμένα τεχνητά στοιχεία και υπερδειγματοληψία κακοηθειών για να συνοδεύουν μια απώλεια σταθμισμένη ανά κατηγορία που ενθαρρύνει την ευαισθησία στην κακοήθεια) διαδραματίζουν κεντρικό ρόλο σε αυτό το έργο.

Με βάση τη ροή δεδομένων που περιγράφεται παραπάνω, η διατριβή προχωρά στην υλοποίηση μιας αρχιτεκτονικής βαθιάς μάθησης βασισμένης σε ένα ConvNeXt-Tiny backbone με channel attention. Σε αυτό το δίκτυο, προστίθεται ένα μπλοκ συμπίεσης και διέγερσης για την επανασταθμισμένη στάθμιση των καναλιών χαρακτηριστικών με βάση το συνολικό πλαίσιο, καθώς και μια συμπαγής κεφαλή ταξινόμησης που εξάγει πιθανότητες κακοήθειας μεταξύ των βαθμολογιών 0 και 1. Η εκπαίδευση πραγματοποιείται σε δύο στάδια: το πρώτο στάδιο περιλαμβάνει μια ενημέρωση μόνο των προστιθέμενων επιπέδων, ακολουθούμενη από ένα δεύτερο στάδιο λεπτομερούς ρύθμισης ορισμένων από τα βαθύτερα επίπεδα του βασικού δικτύου. Η συνάρτηση απώλειας που χρησιμοποιείται είναι η δυαδική διασταυρούμενη κεντροποίηση με στάθμιση κλάσης και αναφέρονται μετρήσεις επικύρωσης ευαισθησίας, ειδικότητας και περιοχής κάτω από την καμπύλη ROC (AUC). Μια σύνθετη στρατηγική πρόωρης διακοπής βασισμένη σε μετρήσεις επικύρωσης που συλλέγονται κατά τη διάρκεια και των δύο σταδίων εκπαίδευσης θα διασφαλίσει ότι το τελικό μοντέλο είναι ικανό για την επιθυμητή ισορροπία μεταξύ ευαισθησίας και συνολικής διακριτικής απόδοσης.

Το εκπαιδευμένο μοντέλο Keras μετατρέπεται στη συνέχεια σε TensorFlow Lite. Αυτό δημιουργεί μικρές εκδόσεις .tflite του μοντέλου που μπορούν να εκτελεστούν σε κινητές συσκευές. Οι έλεγχοι συνέπειας θα επικυρώσουν ότι το μοντέλο TensorFlow Lite έχει απόδοση αρκετά παρόμοια με το αρχικό δίκτυο. Τα αποτελέσματα TFLite αξιολογούνται μέσω αναζήτησης κατωφλίου σε όλο το σύνολο δεδομένων επικύρωσης για την εξισορρόπηση της ευαισθησίας και της ειδικότητας, εξετάζοντας αυτές τις συμβιβαστικές λύσεις μέσω διαφορετικών κατωφλίων απόφασης. Επιπλέον, αυτή η διαδικασία περιλαμβάνει ανάλυση ευαισθησίας μέσω ζωνών ταξινόμησης που ορίζουν ζώνες χαμηλού, μεσαίου και υψηλού κινδύνου σε όλο το φάσμα των πιθανοτήτων, ενώ επιβάλλουν έναν συγκεκριμένο περιορισμό στην αναλογία των κακοήθων βλαβών που αποδίδονται στη ζώνη χαμηλού κινδύνου.

Το τελικό μέρος αυτής της εργασίας είναι η συσκευασία του μοντέλου σε μια εφαρμογή για κινητά που θα αναπτυχθεί χρησιμοποιώντας το πλαίσιο Flutter. Η εφαρμογή θα καθοδηγεί τον χρήστη στη

διαδικασία επιλογής και περικοπής εικόνων, εκτελεί έναν ελαφρύ έλεγχο ποιότητας στην συσκευή σχετικά με την ευκρίνεια και το περιεχόμενο του δέρματος πριν στείλει την προ-επεξεργασμένη εικόνα ως είσοδο στο μοντέλο TensorFlow Lite. Η πιθανότητα κακοήθειας κατατάσσεται σε επίπεδο κινδύνου, σύμφωνα με τα προκαθορισμένα όρια, και συνοδεύεται από επεξηγηματικό κείμενο και ισχυρές δηλώσεις αποποίησης ευθύνης που υποδηλώνουν ότι το εργαλείο δεν αποτελεί διάγνωση και δεν μπορεί να αντικαταστήσει μια κλινική αξιολόγηση.

Συνολικά, αυτοί οι παράγοντες δείχνουν ότι, βασιζόμενοι στις τρέχουσες μεθόδους βαθιάς μάθησης και στην αρχιτεκτονική ανάπτυξης για κινητά, υπάρχει ένα τεχνικά συνεκτικό σύστημα για την ταξινόμηση δερματοσκοπικών εικόνων και την ταξινόμηση κινδύνου. Ταυτόχρονα, αυτή η εργασία καταδεικνύει τις δυσκολίες της εργασίας με ένα σύστημα που έχει αρκετούς σημαντικούς περιοριστικούς παράγοντες που σχετίζονται με την κάλυψη δεδομένων, τη μετατόπιση τομέα, την ερμηνεία από τον χρήστη και την έλλειψη κλινικής επικύρωσης.

Η παρούσα διατριβή παρέχει μια ολοκληρωμένη επισκόπηση του τρόπου με τον οποίο μια συνεχής ροή πληροφοριών μεταφέρεται από ένα συγκεντρωμένο αρχείο δερματοσκοπικών εικόνων σε ένα συγκεντρωμένο εργαλείο αξιολόγησης κινδύνου για κινητά. Η διατριβή χρησιμοποιεί το σύνολο δεδομένων HAM10000 ως αφετηρία για τη δημιουργία μιας μεθόδου φιλτραρίσματος μη έγκυρων καταχωρήσεων από ένα εκπαιδευμένο σύνολο δεδομένων, τη δημιουργία ενός σχήματος ταξινόμησης για την εκχώρηση πολλαπλών κατηγοριών διαγνωστικών ετικετών σε μια δυαδική ταξινόμηση καλοήθους-κακοήθους, την ανάπτυξη ενός στρωματοποιημένου διαχωρισμού εκπαίδευσης-επικύρωσης που διατηρεί την ίδια αναλογία κακοήθων περιπτώσεων και τον ορισμό μιας επαναλαμβανόμενης διαδικασίας για τη χρήση δερματοσκοπικών εικόνων ως συνόλων εκπαίδευσης για εφαρμογές βαθιάς μάθησης. Για να ενισχύσουν περαιτέρω την ικανότητα του μοντέλου να δημιουργεί προβλέψεις με βάση δερματοσκοπικές εικόνες, οι συγγραφείς εφάρμοσαν μια σειρά τεχνικών προεπεξεργασίας και επαύξησης για να τυποποιήσουν τις δερματοσκοπικές εικόνες σε αποσπάσματα εικόνων 256 x 256, ώστε να τις προετοιμάσουν για εισαγωγή σε αλγόριθμους βαθιάς μάθησης, δημιουργώντας παράλληλα έναν μεγάλο αριθμό παραδειγμάτων με υποβάθμιση και παραλλαγές που μιμούνται ρεαλιστικές συνθήκες.

Σαν συνέχεια αυτού του θεμελιώδους έργου, η μελέτη αυτή περιγράφει μια αρχιτεκτονική ταξινόμησης βασισμένη στο ConVNeXt-Tiny και μια μέθοδο αξιολόγησης που σχεδιάστηκε με ένα κανάλι προσοχής Squeeze-and-Excitation (SE) και ένα συμπαγές πυκνό κεφάλι. Οι συγγραφείς χρησιμοποίησαν μια συνάρτηση απώλειας σταθμισμένη ανά κλάση και πρόωρη διακοπή με βάση το AUC και την ευαισθησία ως δύο ξεχωριστά προγράμματα εκπαίδευσης για να εκπαιδεύσουν έναν δυαδικό ταξινομητή με ανισορροπία κλάσεων και κατάφεραν να δημιουργήσουν έναν δυαδικό ταξινομητή ικανό να ταξινομεί κακοήθεις έναντι καλοήθων βλαβών. Αυτός ο ταξινομητής πέτυχε πολύ υψηλά επίπεδα διακριτικής απόδοσης όταν αξιολογήθηκε χρησιμοποιώντας το σύνολο δεδομένων HAM10000, επιβεβαιώνοντας ότι ο συνδυασμός της αρχιτεκτονικής, της διαδικασίας επεξεργασίας δεδομένων και της στρατηγικής βελτιστοποίησης είναι ικανός να δημιουργήσει σημαντικά μοτίβα για χρήση στην επίλυση του προβλήματος διάκρισης μεταξύ καλοήθων και κακοήθων βλαβών.

Μία από τις κύριες συνεισφορές αυτής της εργασίας είναι η σημασία της στενής σύζευξης της αξιολόγησης και της ανάπτυξης. Η διατριβή προχώρησε πέρα από τις μετρήσεις επιπέδου Keras, εξάγοντας το μοντέλο στο TensorFlow Lite (TFLite), συγκρίνοντας την αριθμητική συνέπεια μεταξύ των εκδόσεων Keras και TFLite και πραγματοποιώντας άμεση αναζήτηση κατωφλίου στα αποτελέσματα του TFLite. Με αυτόν τον τρόπο, τα κατώφλια και οι ζώνες κινδύνου που ορίστηκαν για χρήση στην εφαρμογή για κινητά συνδέθηκαν με την πραγματική συμπεριφορά της ίδιας αναπαράστασης μοντέλου που χρησιμοποιήθηκε στις κινητές συσκευές των χρηστών. Η συγκεκριμένη κατασκευή των τριών ζωνών χαμηλού, μεσαίου και υψηλού κινδύνου, καθώς και ο καθορισμένος περιορισμός του ποσοστού κακοήθων βλαβών στη ζώνη χαμηλού κινδύνου, κατέδειξαν πώς η ποσοτική ανάλυση απόδοσης μπορεί να υποστηρίξει συγκεκριμένες αποφάσεις σχετικά με το σχεδιασμό συστημάτων που δίνουν προτεραιότητα στην ασφάλεια των χρηστών.

Από την πλευρά της εφαρμογής, αναπτύχθηκε και ενσωματώθηκε μια εφαρμογή για κινητά με βάση το Flutter, η οποία χρησιμοποιείται με το μοντέλο TFLite ως αυτόνομη μονάδα συμπερασμού. Η εφαρμογή καθοδηγεί τον χρήστη στις διαδικασίες λήψης και περικοπής μιας εικόνας, εφαρμόζοντας ελαφρούς ελέγχους ποιότητας μετά τη λήψη και, στη συνέχεια, εκτελώντας τον τοπικό ταξινομητή στα δεδομένα της εικόνας για να δημιουργήσει ένα μήνυμα κινδύνου (με έναν αριθμό πιθανότητας), καθώς και παρέχοντας μια ρητή δήλωση αποποίησης ευθύνης για τον κίνδυνο. Αυτό δείχνει ότι υπάρχει η τεχνική δυνατότητα να συμπεριληφθούν τα τρέχοντα μοντέλα βαθιάς μάθησης σε συσκευές με περιορισμένους πόρους και ότι αυτό μπορεί να γίνει χωρίς να βασίζεται σε λύσεις που βασίζονται σε διακομιστές, παρέχοντας παράλληλα μια εμπειρία χρήστη που δίνει προτεραιότητα στην προσοχή και τη σαφήνεια.

Ταυτόχρονα, η εργασία αποκάλυψε ορισμένους περιορισμούς σχετικά με το προτεινόμενο σύστημα. Η εκπαίδευση και η επικύρωση του μοντέλου πραγματοποιήθηκαν χρησιμοποιώντας ένα μόνο σύνολο δεδομένων δερματοσκοπιών και δεν έχει ακόμη πραγματοποιηθεί προοπτική κλινική επικύρωση του συστήματος. Επιπλέον, η συμπεριφορά των χρηστών σε απόκριση στα μηνύματα κινδύνου που έλαβαν στην εφαρμογή για κινητά δεν έχει μελετηθεί εμπειρικά. Επομένως, η εργασία πρέπει να θεωρηθεί κυρίως ως απόδειξη της εννοίας ενός συστήματος που ενσωματώνει την τεχνική λύση και το σχέδιο αλληλεπίδρασης με τον χρήστη, και όχι ως ένα ολοκληρωμένο ιατρικό προϊόν. Η συζήτηση γύρω από θέματα όπως η μετατόπιση τομέα, η κάλυψη του συνόλου δεδομένων, η ερμηνευσιμότητα και τα ηθικά ζητήματα παρέχει πληροφορίες για το πώς πρέπει να ερμηνεύεται η υψηλή ποσοτική απόδοση ενός διαγνωστικού εργαλείου πληροφοριών όταν μεταβαίνουμε από σύνολα δεδομένων έρευνας σε μια εφαρμογή στον πραγματικό κόσμο.

Συνοψίζοντας, η κύρια συμβολή αυτής της διατριβής είναι να αποδείξει ότι, λαμβάνοντας υπόψη τις τρέχουσες τεχνολογίες γύρω από τα μοντέλα βαθιάς μάθησης και τα πλαίσια ανάπτυξης για κινητά, είναι δυνατό να δημιουργηθεί ένα συνεκτικό σύστημα που περιλαμβάνει την ταξινόμηση δερματοσκοπικών εικόνων, την αντιστοίχιση των αποτελεσμάτων του μοντέλου με κατηγορίες κινδύνου. Αυτή η ολοκληρωμένη διαδικασία θα μπορούσε να αποτελέσει το σημείο εκκίνησης για μελλοντική συνδυασμένη/πολυεπιστημονική συνεργασία που θα συνδυάζει την εμπειρογνομosύνη στην τεχνολογία μηχανικής μάθησης, την κλινική επικύρωση, τη μελέτη της εμπειρίας των χρηστών και την κανονιστική ανάλυση, με σκοπό τον σχεδιασμό αξιόπιστων, κλινικά και κοινωνικά αποδεκτών συστημάτων.

9.2 Μελλοντικές έρευνες

Οι μελλοντικές έρευνες θα μπορούσαν να ξεκινήσουν με την επέκταση και την επαλήθευση της εμπειρικής βάσης του συστήματος. Η εκπαίδευση και η αξιολόγηση έχουν πραγματοποιηθεί σε ένα μόνο σύνολο δεδομένων δερματοσκοπίας, οπότε η χρήση της ίδιας διαδικασίας σε επιπλέον σύνολα δεδομένων, συμπεριλαμβανομένων συνόλων δεδομένων με μεγαλύτερη ποικιλία τύπων δέρματος και συνθηκών λήψης, θα παρείχε μια πιο αξιόπιστη εικόνα της απόδοσης και της γενίκευσης. Ιδιαίτερα πολύτιμα θα ήταν τα εξωτερικά σύνολα δοκιμών και, τελικά, η προοπτική αξιολόγηση εικόνων που έχουν ληφθεί σε ρεαλιστικά σενάρια χρήσης σε συσκευές καταναλωτών. Η διερεύνηση εναλλακτικών αρχιτεκτονικών μοντελοποίησης, η πιο συστηματική βελτιστοποίηση υπερπαραμέτρων και η ρητή βαθμονόμηση πιθανοτήτων θα ήταν χρήσιμες έρευνες για τη βελτίωση τόσο της ακρίβειας όσο και της αξιοπιστίας των προβλεπόμενων βαθμολογιών κινδύνου.

Μια δεύτερη σημαντική οδός είναι φυσικά η αλληλεπίδραση χρήστη/κλινικού ιατρού. Η τρέχουσα εφαρμογή για κινητά έχει σχεδιαστεί ώστε να έχει μια βασική ροή για την αξιολόγηση μιας μεμονωμένης εικόνας, η οποία παρέχει μόνο περιορισμένη ανατροφοδότηση (δηλ. τις τρεις κατηγορίες κινδύνου μαζί με μια επεξηγηματική επιστροφή κειμένου). Μελλοντικές εκδόσεις μπορεί να διερευνήσουν πλουσιότερα μοτίβα αλληλεπίδρασης, όπως διαχρονική μελέτη παρακολούθησης βλαβών, βελτιωμένη καθοδήγηση για τη λήψη ή προαιρετικές οπτικές εξηγήσεις για το σημείο στο οποίο έχει εστιάσει το μοντέλο εντός της εικόνας. Οποιαδήποτε εργασία προς την κατεύθυνση της εφαρμογής στον πραγματικό κόσμο θα απαιτούσε επίσης τελικά επίσημη κλινική επικύρωση,

αξιολόγηση του τι θα κάνουν οι χρήστες (και πώς αντιλαμβάνονται) τα μηνύματα κινδύνου, καθώς και εξέταση των κανονιστικών απαιτήσεων για να διασφαλιστεί ότι οποιεσδήποτε τεχνικές βελτιώσεις συνοδεύονται από αποδεικτικά στοιχεία που υποστηρίζουν την ασφάλεια, τη χρηστικότητα και την κλινική αξία.

Η δεύτερη σειρά μελετών για τη βελτίωση της συνολικής απόδοσης του μοντέλου περιλαμβάνει την αρχιτεκτονική ή τη βαθμονόμηση του μοντέλου. Θα ήταν ενδιαφέρον να αξιολογηθούν άλλες αρχιτεκτονικές, όπως ελαφριά δίκτυα βελτιστοποιημένα για κινητά ή μοντέλα Vision Transformer, εκτελώντας τα μέσω της ίδιας διαδικασίας ή των ίδιων διαδικασιών αξιολόγησης που εκτελέστηκαν με το μοντέλο ConVNeXt-Tiny. Περαιτέρω βελτιώσεις μπορούν να επιτευχθούν μέσω μιας πιο συστηματικής μεθόδου βελτιστοποίησης των υπερπαραμέτρων, χρησιμοποιώντας μεθόδους όπως η αυτοματοποιημένη βελτιστοποίηση υπερπαραμέτρων με χρήση πολλαπλών παραμέτρων αναζήτησης για το ρυθμό μάθησης, την αύξηση και τα σχήματα στάθμισης κλάσεων. Θα ήταν επωφελές να διερευνηθεί περαιτέρω η ρητή βαθμονόμηση για τον προσδιορισμό της ακρίβειας και της αβεβαιότητας της προβλεπόμενης πιθανότητας για την παρατηρούμενη συχνότητα της κακοήθειας και, ως εκ τούτου, για τον καθορισμό πολύ ακριβών ζωνών κινδύνου και επικοινωνιών κινδύνου.

Ο τρίτος σημαντικός τομέας μελλοντικής έρευνας θα περιλαμβάνει την προσθήκη πλουσιότερων δεδομένων εισόδου και προβλεπόμενων αποτελεσμάτων. Κλινικά μεταδεδομένα όπως η ηλικία του ασθενούς, το φύλο, η θέση της βλάβης θα μπορούσαν να ενσωματωθούν σε ένα ολοκληρωμένο πολυτροπικό μοντέλο. Διευκολύνει τη βελτίωση των διαγνώσεων/προβλέψεων των βλαβών που βασίζονται σε εικόνες, ενσωματώνοντας χαρακτηριστικά που εξάγονται από εικόνες με δομημένα κλινικά δεδομένα. Το δυαδικό μοντέλο ταξινόμησης χρησιμοποιείται επί του παρόντος ως εργαλείο υποστήριξης αξιολόγησης κίνδυνου και όχι ως διαγνωστικό μέσο. Ωστόσο, είναι δυνατή η ταξινόμηση σε πολλαπλές κατηγορίες, καθώς και η ανάπτυξη πολλαπλών λειτουργιών χρησιμοποιώντας ένα μοντέλο για τον προσδιορισμό τόσο των διαγνωστικών τύπων ταξινόμησης για δερματικές βλάβες/ελιές.

Εκτός από την ανάπτυξη βελτιωμένων αλγορίθμων για το υπάρχον εργαλείο, υπάρχουν πολλές δυνατότητες έρευνας σχετικά με την εμπειρία των χρηστών και την ενσωμάτωση των κλινικών ιατρών στις κλινικές ροές εργασίας. Οι μελλοντικές πιθανές κατευθύνσεις της έρευνας περιλαμβάνουν τη διερεύνηση της αλληλεπίδρασης των χρηστών του εργαλείου (ασθενείς και πάροχοι) με το εργαλείο, την αντίληψη και την κατανόηση των χρηστών σχετικά με τα μηνύματα κατηγορίας κινδύνου, τον τρόπο με τον οποίο η εφαρμογή εντάσσεται στις υπάρχουσες κλινικές ροές εργασίας (δηλ. τηλεδερματολογία, διαλογή πρωτοβάθμιας περίθαλψης), το κατά πόσον η εφαρμογή προάγει την έγκαιρη ιατρική συμβουλή σχετικά με ανησυχητικές βλάβες και το κατά πόσον η εφαρμογή προκαλεί αυξημένο άγχος ή οδηγεί σε περιττές συμβουλές, καθώς και το πώς οι διαφορετικές διατυπώσεις των μηνυμάτων κινδύνου και το γραφικό υλικό μεταβάλλουν τη συμπεριφορά και την ερμηνεία των χρηστών.

Ένας λογικός τομέας για μελλοντική έρευνα είναι η δικαιοσύνη και τα πρότυπα διακυβέρνησης/κοινότητας/ρύθμισης. Μια αξιολογική μελέτη θα πρέπει να διαστρωματοποιήσει τους πληθυσμούς του δείγματος ώστε να συμπεριλάβει μεταβλητές όπως η ηλικία, το φύλο, ο τύπος δέρματος κ.λπ., για να επαληθεύσει ότι το εργαλείο λειτουργεί εξίσου καλά σε όλες τις δημογραφικές ομάδες με διαφορετικούς τύπους δέρματος και να διαπιστώσει εάν υπάρχουν συστηματικές μεροληψίες στο σύστημα. Εκτός από αυτή την ανάγκη, οι μελλοντικές εφαρμογές των τεχνολογιών τεχνητής νοημοσύνης στην κλινική πρακτική απαιτούν την τήρηση κοινοτικών και κανονιστικών προτύπων σχετικά με την παρακολούθηση και την επιτήρηση λογισμικού που ταξινομείται ως ιατρικές συσκευές (συμπεριλαμβανομένων, ενδεικτικά): έγγραφο που δηλώνει την προβλεπόμενη χρήση, παροχή αποδεικτικών στοιχείων για την υποστήριξη της κανονιστικής έγκρισης, δημιουργία μηχανισμών παρακολούθησης μετά τη διάθεση στην αγορά και εφαρμογή σχεδίων διαχείρισης κινδύνου. Απαιτούνται επίσης στοιχεία προστασίας της ιδιωτικής ζωής και μηχανισμοί πλήρους συναίνεσης πριν τα δεδομένα των ασθενών μπορούν να χρησιμοποιηθούν για σκοπούς επανεκπαίδευσης του αλγορίθμου ή παρακολούθησης δυσλειτουργιών.

Χρησιμοποιώντας την εφαρμογή ευρύτερων διαχρονικών και διαδραστικών χαρακτηριστικών για την εφαρμογή και για μεμονωμένες βλάβες/ελιές, μπορεί να είναι δυνατό να δημιουργηθούν χαρακτηριστικά για να συνδυάσουν την αναγνώριση πιθανών κλινικά σχετικών αλλαγών στη βλάβη/ελιά με την ασφαλή αποθήκευση εικόνων στο πέρασμα του χρόνου στη συσκευή του ασθενούς και να βοηθήσουν τους ασθενείς να παρακολουθούν τις αλλαγές στις βλάβες τους. Επιπλέον, η χρήση εικόνων που δημιουργούνται από τους χρήστες κατά τη διαδικασία λήψης εικόνων θα αποτελούσε μια ακόμη χρήσιμη μορφή λειτουργικότητας. Ομοίως, η άμεση ενημέρωση των χρηστών σχετικά με τις περιοχές της εικόνας που συμβάλλουν στη συνολική αξιολόγηση μέσω οπτικών εξηγήσεων θα αποτελούσε μια πιθανή βελτίωση για μελλοντικές εκδόσεις της εφαρμογής. Κάθε βελτίωση θα πρέπει επίσης να υποβληθεί σε αξιολογήσεις σχετικά με τη χρηστικότητα, την ασφάλεια και την κλινική σημασία. Η ανάπτυξη συνεργασιών και η αξιοποίηση των εισροών από δερματολόγους, γενικούς ιατρούς, σχεδιαστές UX και εμπειρογνώμονες σε θέματα κανονιστικής συμμόρφωσης θα είναι κρίσιμης σημασίας για την αποτελεσματική αξιολόγηση αυτού του εργαλείου.

Συμπερασματικά, η παρόν εργασία παρουσιάζει τις αρχικές φάσεις ανάπτυξης που έχουν επιτευχθεί μέχρι σήμερα, χρησιμεύει ως βάση για μελλοντική έρευνα που αξιοποιεί αυτές τις πληροφορίες για τη βελτίωση του εργαλείου αξιολόγησης κινδύνου του δέρματος για κινητά και βασίζεται στα εξελισσόμενα ρυθμιστικά/ηθικά/κλινικά πλαίσια που επιβάλλονται στις τεχνολογίες τεχνητής νοημοσύνης στην πρακτική της δερματολογίας.

ΒΙΒΛΙΟΓΡΑΦΙΑ

- [1] <https://encrypted-tbn0.gstatic.com/images?q=tbn:ANd9GcQYWG0IblQeYypOG7TAV474LGZhErhZmLEeJ0CXaNh3Q-yTNgUGLygYAgzY2NFapAa7RvI&usqp=CAU>
- [2] <https://dermapapageorgiou.gr/wp-content/uploads/2025/07/melanoma-diagnosi-320x320.jpg>
- [3] <https://www.researchgate.net/publication/381359133/figure/fig3/AS:11431281632008439@1757637393794/A-ConvNext-Tiny-network-structure-B-ConvNext-Block-structure.tif>
- [4] M. Aleem, N. Hameed, A. Anjum, and F. Hameed, “m-Skin Doctor: A mobile enabled system for early melanoma skin cancer detection using support vector machine,” *eHealth*, vol. 2, pp. 468–475, Dec. 2016.
- [5] Ali, Z., Yousaf, N. and Larkin, J., 2013. Melanoma epidemiology, biology and prognosis. *European Journal of Cancer Supplements*, 11(2), pp.81-91.
- [6] Arnold, M., Singh, D., Laversanne, M., Vignat, J., Vaccarella, S., Meheus, F., Cust, A.E., De Vries, E., Whiteman, D.C. and Bray, F., 2022. Global burden of cutaneous melanoma in 2020 and projections to 2040. *JAMA dermatology*, 158(5), pp.495-503.
- [7] Balch, C.M., Gershenwald, J.E., Soong, S.J., Thompson, J.F., Atkins, M.B., Byrd, D.R., Buzaid, A.C., Cochran, A.J., Coit, D.G., Ding, S. and Eggermont, A.M., 2009. Final version of 2009 AJCC melanoma staging and classification. *Journal of clinical oncology*, 27(36), pp.6199-6206.
- [8] Nachbar, F., Stolz, W., Merkle, T., Cognetta, A.B., Vogt, T., Landthaler, M., Bilek, P., Braun-Falco, O. and Plewig, G., 1994. The ABCD rule of dermatoscopy: high prospective value in the diagnosis of doubtful melanocytic skin lesions. *Journal of the American Academy of Dermatology*, 30(4), pp.551-559.
- [9] Kittler, H., Pehamberger, H., Wolff, K. and Binder, M.J.T.I.O., 2002. Diagnostic accuracy of dermoscopy. *The lancet oncology*, 3(3), pp.159-165.
- [10] Tschandl, P., Rosendahl, C. and Kittler, H., 2018. The HAM10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions. *Scientific data*, 5(1), pp.1-9.
- [11] LeCun, Y., Bengio, Y. and Hinton, G., 2015. Deep learning. *nature*, 521(7553), pp.436-444.
- [12] He, K., Zhang, X., Ren, S. and Sun, J., 2016. Deep residual learning for image recognition. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 770-778).
- [13] Esteva, A., Kuprel, B., Novoa, R.A., Ko, J., Swetter, S.M., Blau, H.M. and Thrun, S., 2017. Correction: Corrigendum: Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 546(7660), pp.686-686.
- [14] Rat, C., Hild, S., Rault Sérandour, J., Gaultier, A., Quereux, G., Dreno, B. and Nguyen, J.M., 2018. Use of smartphones for early detection of melanoma: systematic review. *Journal of medical Internet research*, 20(4), p.e135.

- [15] Shorten, C. and Khoshgoftaar, T.M., 2019. A survey on image data augmentation for deep learning. *Journal of big data*, 6(1), pp.1-48.
- [16] Liu, Z., Mao, H., Wu, C.Y., Feichtenhofer, C., Darrell, T. and Xie, S., 2022. A convnet for the 2020s. In *Proceedings of the IEEE/CVF conference on computer vision and pattern recognition* (pp. 11976-11986).
- [17] Hu, J., Shen, L. and Sun, G., 2018. Squeeze-and-excitation networks. In *Proceedings of the IEEE conference on computer vision and pattern recognition* (pp. 7132-7141).
- [18] Mandrekar, J.N., 2010. Receiver operating characteristic curve in diagnostic test assessment. *Journal of thoracic oncology*, 5(9), pp.1315-1316.
- [19] Hajian-Tilaki, K., 2018. The choice of methods in determining the optimal cut-off value for quantitative diagnostic test evaluation. *Statistical methods in medical research*, 27(8), pp.2374-2383.
- [20] Hassanaly, P. and Dufour, J.C., 2021. Analysis of the regulatory, legal, and medical conditions for the prescription of mobile health applications in the United States, the European Union, and France. *Medical Devices: Evidence and Research*, pp.389-409.
- [21] Sigle, M., Heurich, D., Faller, W., Gawaz, M., Mueller, K.A.L. and Goldschmied, A., 2025. AI-guided refinement of coronary revascularization need in patients suspected of acute coronary syndrome. *European Heart Journal-Digital Health*, p.ztaf106.
- [22] Saraswathi, P., Khaliq, A., Hariprasath, N. and Prabha, M., 2024, December. A Deep Learning-Based Scene Description and Object Recognition App for the Visually Impaired. In *2024 International Conference on Sustainable Communication Networks and Application (ICSCNA)* (pp. 1426-1431). IEEE.
- [23] Misra, M.K., On-Device AI for Privacy-Preserving Mobile Applications: A Framework using TensorFlow Lite.
- [24] Bansal, R., Raj, G. and Choudhury, T., 2016, November. Blur image detection using Laplacian operator and Open-CV. In *2016 International Conference System Modeling & Advancement in Research Trends (SMART)* (pp. 63-67). IEEE.
- [25] Shaik, K.B., Ganesan, P., Kalist, V., Sathish, B.S. and Jenitha, J.M.M., 2015. Comparative study of skin color detection and segmentation in HSV and YCbCr color space. *Procedia Computer Science*, 57, pp.41-48.
- [26] Lang, S., McIntosh, J.G., Enticott, J., Goldstein, R., Baker, S., McGowan, M., Cooray, S., Du, L., Reddy, A., Harrison, C.L. and Thong, E., 2025. Exploring the acceptability of a risk prediction tool for cardiometabolic risk (gestational diabetes and hypertensive disorders of pregnancy) for use in early pregnancy: A qualitative study. *Midwifery*, 141, p.104270.
- [27] Chen, L., 2020. Overview of clinical prediction models. *Annals of translational medicine*, 8(4), p.71.
- [28] Stacke, K., Eilertsen, G., Unger, J. and Lundström, C., 2020. Measuring domain shift for deep learning in histopathology. *IEEE journal of biomedical and health informatics*, 25(2), pp.325-336.
- [29] Montoya, L.N., Roberts, J.S. and Hidalgo, B.S., 2025, March. Towards fairness in AI for melanoma detection: Systemic review and recommendations. In *Future of Information and Communication Conference* (pp. 320-341). Cham: Springer Nature Switzerland.

- [30] Tschandl, P., 2020. Problems and potentials of automated object detection for skin cancer recognition. *JAMA dermatology*, 156(1), pp.23-24.
- [31] Daneshjou, R., Barata, C., Betz-Stablein, B., Celebi, M.E., Codella, N., Combalia, M., Guitera, P., Gutman, D., Halpern, A., Helba, B. and Kittler, H., 2022. Checklist for evaluation of image-based artificial intelligence reports in dermatology: CLEAR derm consensus guidelines from the international skin imaging collaboration artificial intelligence working group. *JAMA dermatology*, 158(1), pp.90-96.
- [32] Visschers, V.H., Meertens, R.M., Passchier, W.W. and De Vries, N.N., 2009. Probability information in risk communication: a review of the research literature. *Risk Analysis: An International Journal*, 29(2), pp.267-287.

ΠΑΡΑΡΤΗΜΑ Α : Κώδικας Μηχανικής Μάθησης

Στο συγκεκριμένο παράρτημα παρουσιάζεται ο κώδικας της μηχανικής μάθησης, όπως χρησιμοποιήθηκε.

Training Script

```
import os
import io
import random
import time
import math
from typing import Tuple

import numpy as np
import pandas as pd
from PIL import Image, ImageDraw, ImageFilter

import tensorflow as tf
from sklearn.model_selection import StratifiedShuffleSplit
from sklearn.metrics import roc_auc_score, confusion_matrix

HAM_IMAGES_DIR = r"C:\MelanomaCheckApp\ModelTrain\dataverse_files\merged"
HAM_METADATA_CSV = r"C:\MelanomaCheckApp\ModelTrain\dataverse_files\HAM10000_metadata.csv"

IMG_SIZE = 256
RANDOM_SEED = 1337

BATCH_SIZE = 32
PHASE1_MAX_EPOCHS = 30
PHASE2_MAX_EPOCHS = 15
EARLY_STOP_PATIENCE = 5
```

```

MALIGNANT_SET = {"akiec", "bcc", "mel"}
BENIGN_SET = {"bkl", "nv", "vasc", "df"}

random.seed(RANDOM_SEED)
np.random.seed(RANDOM_SEED)
tf.random.set_seed(RANDOM_SEED)

def dx_to_binlabel(dx: str) -> int:
    if dx in MALIGNANT_SET:
        return 1
    if dx in BENIGN_SET:
        return 0
    raise ValueError(f"Unknown dx {dx}")

def center_crop_square(pil_img: Image.Image) -> Image.Image:
    w, h = pil_img.size
    side = min(w, h)
    left = (w - side) // 2
    top = (h - side) // 2
    return pil_img.crop((left, top, left + side, top + side))

def add_random_hairs(
    pil_img: Image.Image,
    max_hairs: int = 3,
    thickness_range: Tuple[int, int] = (1, 3),
    opacity_range=(120, 200),
    color=(0, 0, 0),
) -> Image.Image:
    img = pil_img.convert("RGBA")
    overlay = Image.new("RGBA", img.size, (0, 0, 0, 0))
    draw = ImageDraw.Draw(overlay)

    w, h = img.size

```

```

num_hairs = random.randint(0, max_hairs)

for _ in range(num_hairs):
    t = random.randint(*thickness_range)
    alpha = random.randint(*opacity_range)

    x1, y1 = random.randint(0, w), random.randint(0, h)
    x2, y2 = random.randint(0, w), random.randint(0, h)
    cx = (x1 + x2) / 2 + random.randint(-w // 8, w // 8)
    cy = (y1 + y2) / 2 + random.randint(-h // 8, h // 8)

    points = []
    steps = 20
    for step in range(steps + 1):
        t_rel = step / steps
        xt = (1 - t_rel) ** 2 * x1 + 2 * (1 - t_rel) * t_rel * cx + (t_rel**2) * x2
        yt = (1 - t_rel) ** 2 * y1 + 2 * (1 - t_rel) * t_rel * cy + (t_rel**2) * y2
        points.append((xt, yt))

    draw.line(points, fill=(color[0], color[1], color[2], alpha), width=t)

out = Image.alpha_composite(img, overlay).convert("RGB")
return out

def jpeg_compress_like(pil_img: Image.Image, q_low=30, q_high=90) -> Image.Image:
    buf = io.BytesIO()
    pil_img.save(buf, format="JPEG", quality=random.randint(q_low, q_high))
    buf.seek(0)
    out = Image.open(buf).convert("RGB")
    return out

def augment_pil(pil_img: Image.Image) -> Image.Image:
    if random.random() < 0.5:

```

```

    pil_img = pil_img.transpose(Image.FLIP_LEFT_RIGHT)
if random.random() < 0.2:
    pil_img = pil_img.transpose(Image.FLIP_TOP_BOTTOM)

if random.random() < 0.5:
    angle = random.uniform(-20, 20)
    pil_img = pil_img.rotate(angle, resample=Image.BILINEAR)

if random.random() < 0.5:
    w, h = pil_img.size
    zoom_scale = random.uniform(0.8, 1.0)
    new_w = int(w * zoom_scale)
    new_h = int(h * zoom_scale)
    left = random.randint(0, w - new_w)
    top = random.randint(0, h - new_h)
    pil_img = pil_img.crop((left, top, left + new_w, top + new_h))
    pil_img = pil_img.resize((IMG_SIZE, IMG_SIZE), Image.BILINEAR)

if random.random() < 0.8:
    b_factor = random.uniform(0.8, 1.2)
    pil_img = ImageEnhance_Brightness(pil_img, b_factor)
    c_factor = random.uniform(0.8, 1.2)
    pil_img = ImageEnhance_Contrast(pil_img, c_factor)
    s_factor = random.uniform(0.8, 1.2)
    pil_img = ImageEnhance_Color(pil_img, s_factor)

if random.random() < 0.3:
    if random.random() < 0.5:
        pil_img = pil_img.filter(
            ImageFilter.GaussianBlur(radius=random.uniform(0.1, 1.5))
        )
    else:
        pil_img = jpeg_compress_like(pil_img)

```

```

pil_img = add_random_hairs(pil_img, max_hairs=3)

return pil_img

from PIL import ImageEnhance

def ImageEnhance_Brightness(img, factor):
    return ImageEnhance.Brightness(img).enhance(factor)

def ImageEnhance_Contrast(img, factor):
    return ImageEnhance.Contrast(img).enhance(factor)

def ImageEnhance_Color(img, factor):
    return ImageEnhance.Color(img).enhance(factor)

def load_process_image(path, train=True):
    img = Image.open(path).convert("RGB")
    img = center_crop_square(img)
    img = img.resize((IMG_SIZE, IMG_SIZE), Image.BILINEAR)

    if train:
        img = augment_pil(img)

    arr = np.asarray(img, dtype=np.float32)
    return arr

def make_tf_data(df, train=True, shuffle=True, batch_size=32):
    paths = [
        os.path.join(HAM_IMAGES_DIR, f"{img_id}.jpg")
        for img_id in df["image_id"].tolist()
    ]
    labels = df["label_bin"].astype("float32").tolist()

```

```

def gen():
    for p, y in zip(paths, labels):
        yield p, np.float32(y)

ds = tf.data.Dataset.from_generator(
    gen,
    output_signature=(
        tf.TensorSpec(shape=(), dtype=tf.string),
        tf.TensorSpec(shape=(), dtype=tf.float32),
    ),
)

def _py_loader(path_tensor, label_tensor):
    p = path_tensor.numpy().decode("utf-8")
    arr = load_process_image(p, train=train)
    y_val = label_tensor.numpy().astype("float32")
    return arr, y_val

def wrapper(path_tensor, label_tensor):
    img_arr, y_val = tf.py_function(
        func=_py_loader,
        inp=[path_tensor, label_tensor],
        Tout=[tf.float32, tf.float32],
    )
    img_arr.set_shape([IMG_SIZE, IMG_SIZE, 3])
    y_val.set_shape([])
    return img_arr, y_val

ds = ds.map(wrapper, num_parallel_calls=tf.data.AUTOTUNE)

if shuffle:
    ds = ds.shuffle(

```

```

        buffer_size=len(df),
        seed=RANDOM_SEED,
        reshuffle_each_iteration=True,
    )

    ds = ds.batch(batch_size).prefetch(tf.data.AUTOTUNE)
    return ds

def oversample_malignant(df_train: pd.DataFrame) -> pd.DataFrame:
    benign_df = df_train[df_train.label_bin == 0]
    mal_df = df_train[df_train.label_bin == 1]

    num_benign = len(benign_df)
    num_mal = len(mal_df)

    if num_mal == 0:
        return df_train.copy()

    if num_mal < num_benign:
        reps = math.ceil(num_benign / num_mal)
        mal_df_up = pd.concat([mal_df] * reps, ignore_index=True).iloc[:num_benign]
        new_df = pd.concat([benign_df, mal_df_up], ignore_index=True)
    else:
        new_df = df_train.copy()

    new_df = new_df.sample(frac=1.0, random_state=RANDOM_SEED).reset_index(drop=True)
    return new_df

class SensitivityMetric(tf.keras.metrics.Metric):
    def __init__(self, name="sensitivity", **kwargs):
        super().__init__(name=name, **kwargs)
        self.tp = self.add_weight(name="tp", initializer="zeros")
        self.fn = self.add_weight(name="fn", initializer="zeros")

```

```
def update_state(self, y_true, y_pred, sample_weight=None):
```

```
    y_true = tf.cast(y_true, tf.float32)
    y_pred_bin = tf.cast(y_pred >= 0.5, tf.float32)
    tp = tf.reduce_sum(y_pred_bin * y_true)
    fn = tf.reduce_sum((1.0 - y_pred_bin) * y_true)
    self.tp.assign_add(tp)
    self.fn.assign_add(fn)
```

```
def result(self):
```

```
    return self.tp / (self.tp + self.fn + 1e-8)
```

```
def reset_states(self):
```

```
    self.tp.assign(0.0)
    self.fn.assign(0.0)
```

```
class SpecificityMetric(tf.keras.metrics.Metric):
```

```
    def __init__(self, name="specificity", **kwargs):
```

```
        super().__init__(name=name, **kwargs)
        self.tn = self.add_weight(name="tn", initializer="zeros")
        self.fp = self.add_weight(name="fp", initializer="zeros")
```

```
    def update_state(self, y_true, y_pred, sample_weight=None):
```

```
        y_true = tf.cast(y_true, tf.float32)
        y_pred_bin = tf.cast(y_pred >= 0.5, tf.float32)
        tn = tf.reduce_sum((1.0 - y_pred_bin) * (1.0 - y_true))
        fp = tf.reduce_sum(y_pred_bin * (1.0 - y_true))
        self.tn.assign_add(tn)
        self.fp.assign_add(fp)
```

```
    def result(self):
```

```
        return self.tn / (self.tn + self.fp + 1e-8)
```

```

def reset_states(self):
    self.tn.assign(0.0)
    self.fp.assign(0.0)

def eval_on_dataset(model, ds_val):
    all_probs = []
    all_true = []
    for batch_x, batch_y in ds_val:
        probs = model(batch_x, training=False).numpy().reshape(-1)
        all_probs.extend(probs.tolist())
        all_true.extend(batch_y.numpy().reshape(-1).tolist())

    all_probs = np.array(all_probs)
    all_true = np.array(all_true).astype(int)
    y_pred_bin = (all_probs >= 0.5).astype(int)

    try:
        auc = roc_auc_score(all_true, all_probs)
    except ValueError:
        auc = float("nan")

    if len(np.unique(all_true)) == 2:
        tn, fp, fn, tp = confusion_matrix(all_true, y_pred_bin).ravel()
    else:
        tn = fp = fn = tp = 0

    sens = tp / (tp + fn + 1e-8)
    spec = tn / (tn + fp + 1e-8)
    acc = (tp + tn) / (tp + tn + fp + fn + 1e-8)

    return {
        "auc": auc,
        "sensitivity": sens,

```

```

    "specificity": spec,
    "acc": acc,
    "tp": tp,
    "fp": fp,
    "tn": tn,
    "fn": fn,
}

```

```
def squeeze_excite_block(x, reduction=16, name="se"):
```

```

    filters = x.shape[-1]
    se = tf.keras.layers.GlobalAveragePooling2D(name=f"{name}_gap")(x)
    se = tf.keras.layers.Dense(
        filters // reduction,
        activation="relu",
        use_bias=False,
        name=f"{name}_fc1",
    )(se)
    se = tf.keras.layers.Dense(
        filters,
        activation="sigmoid",
        use_bias=False,
        name=f"{name}_fc2",
    )(se)
    se = tf.keras.layers.Reshape((1, 1, filters), name=f"{name}_reshape")(se)
    x = tf.keras.layers.Multiply(name=f"{name}_scale")(x, se)
    return x

```

```
def build_model(backbone_trainable=False, unfreeze_last_n=None):
```

```

    base = tf.keras.applications.ConvNeXtTiny(
        include_top=False,
        include_preprocessing=True,
        weights="imagenet",
        input_shape=(IMG_SIZE, IMG_SIZE, 3),

```

```

        pooling=None,
    )

    base.trainable = False

    if backbone_trainable and (unfreeze_last_n is not None):
        for layer in base.layers[-unfreeze_last_n:]:
            layer.trainable = True

    inputs = tf.keras.Input(shape=(IMG_SIZE, IMG_SIZE, 3), name="input_image")

    x = base(inputs, training=False)
    x = squeeze_excite_block(x, reduction=16, name="se_block")

    x = tf.keras.layers.GlobalAveragePooling2D(name="global_avg_pool")(x)
    x = tf.keras.layers.Dense(128, activation="relu", name="dense_128")(x)
    x = tf.keras.layers.Dropout(0.5, name="dropout")(x)
    outputs = tf.keras.layers.Dense(1, activation="sigmoid", name="pred")(x)

    model = tf.keras.Model(inputs, outputs, name="lesion_convnexttiny_bin")
    return model, base

def compile_model(model, lr):
    opt = tf.keras.optimizers.AdamW(learning_rate=lr)
    model.compile(
        optimizer=opt,
        loss="binary_crossentropy",
        metrics=[
            tf.keras.metrics.AUC(name="auc", curve="ROC"),
            SensitivityMetric(),
            SpecificityMetric(),
            tf.keras.metrics.BinaryAccuracy(name="acc", threshold=0.5),
        ],

```

)

```
class DualEarlyStopper(tf.keras.callbacks.Callback):
    def __init__(self, ds_val, patience, phase_name):
        super().__init__()
        self.ds_val = ds_val
        self.patience = patience
        self.phase_name = phase_name
        self.best_auc = -np.inf
        self.best_sens = -np.inf
        self.wait = 0
        self.best_weights = None
        self.best_metrics = None
        self.best_epoch = -1

    def on_epoch_end(self, epoch, logs=None):
        metrics = eval_on_dataset(self.model, self.ds_val)
        auc = metrics["auc"]
        sens = metrics["sensitivity"]
        spec = metrics["specificity"]
        acc = metrics["acc"]
        print(
            f"[{self.phase_name}] epoch {epoch+1} "
            f"val_auc={auc:.4f} sens={sens:.4f} spec={spec:.4f} acc={acc:.4f}"
        )

        improved = False
        if auc > self.best_auc:
            improved = True
        if sens > self.best_sens:
            improved = True

        if improved:
```

```

self.best_auc = max(self.best_auc, auc)
self.best_sens = max(self.best_sens, sens)
self.best_weights = self.model.get_weights()
self.best_metrics = metrics
self.best_epoch = epoch
self.wait = 0

print(" improvement, saving best weights in RAM")
else:
    self.wait += 1

    print(f" no improvement for {self.wait} epochs")

if self.wait >= self.patience:
    print(" Early stopping trigger")
    self.model.stop_training = True

def on_train_end(self, logs=None):
    if self.best_weights is not None:
        print(f"Restoring best weights from epoch {self.best_epoch+1}")
        self.model.set_weights(self.best_weights)

def main():
    meta = pd.read_csv(HAM_METADATA_CSV)
    meta = meta[["image_id", "dx"]].copy()

    meta["label_bin"] = meta["dx"].apply(dx_to_binlabel)

    meta["exists"] = meta["image_id"].apply(
        lambda iid: os.path.exists(os.path.join(HAM_IMAGES_DIR, f"{iid}.jpg"))
    )
    df_full = meta[meta["exists"]].reset_index(drop=True)

    print("Class balance (full):\n", df_full["label_bin"].value_counts())

```

```

splitter = StratifiedShuffleSplit(
    n_splits=1,
    test_size=0.2,
    random_state=RANDOM_SEED,
)
train_idx, val_idx = next(splitter.split(df_full, df_full["label_bin"]))
df_train = df_full.iloc[train_idx].reset_index(drop=True)
df_val = df_full.iloc[val_idx].reset_index(drop=True)

print("Class balance (train):\n", df_train["label_bin"].value_counts())
print("Class balance (val):\n", df_val["label_bin"].value_counts())

df_train_bal = oversample_malignant(df_train)
print(
    "Class balance (train AFTER oversample):\n",
    df_train_bal["label_bin"].value_counts(),
)

ds_train = make_tf_data(
    df_train_bal, train=True, shuffle=True, batch_size=BATCH_SIZE
)
ds_val = make_tf_data(df_val, train=False, shuffle=False, batch_size=BATCH_SIZE)

neg = (df_train["label_bin"] == 0).sum()
pos = (df_train["label_bin"] == 1).sum()
if pos == 0:
    pos = 1
pos_weight = neg / pos
class_weight = {0: 1.0, 1: pos_weight}
print("class_weight", class_weight)

model, backbone = build_model(backbone_trainable=False)

```

```

compile_model(model, lr=1e-3)
cb_phase1 = DualEarlyStopper(
    ds_val=ds_val,
    patience=EARLY_STOP_PATIENCE,
    phase_name="phase1",
)

history1 = model.fit(
    ds_train,
    epochs=PHASE1_MAX_EPOCHS,
    validation_data=ds_val,
    class_weight=class_weight,
    callbacks=[cb_phase1],
    verbose=1,
)

N_UNFREEZE = 30
for layer in backbone.layers[-N_UNFREEZE:]:
    layer.trainable = True

compile_model(model, lr=1e-5)
cb_phase2 = DualEarlyStopper(
    ds_val=ds_val,
    patience=EARLY_STOP_PATIENCE,
    phase_name="phase2",
)

history2 = model.fit(
    ds_train,
    epochs=PHASE2_MAX_EPOCHS,
    validation_data=ds_val,
    class_weight=class_weight,
    callbacks=[cb_phase2],

```

```

        verbose=1,
    )

    final_metrics = eval_on_dataset(model, ds_val)
    print("\n=== Final Validation Metrics ===")
    for k, v in final_metrics.items():
        print(f'{k}: {v:.4f}')

    timestamp = int(time.time())
    saved_keras_path = f"lesion_convnexttiny_best_{timestamp}.keras"
    model.save(saved_keras_path)
    print(f"Saved Keras model to {saved_keras_path}")

    converter = tf.lite.TFLiteConverter.from_keras_model(model)
    tflite_model = converter.convert()

    tflite_path = f"lesion_convnexttiny_best_{timestamp}.tflite"
    with open(tflite_path, "wb") as f:
        f.write(tflite_model)

    print(f"TFLite model written to {tflite_path}")
    print("Done.")

if __name__ == "__main__":
    main()

```

exportToTfLite

```

import tensorflow as tf
import np as np

MODEL_PATH
r"E:\Downloads\melanoma_binary_pipeline\lesion_convnexttiny_best_1762112837.keras"

```

```

IMG_SIZE = 256

def squeeze_excite_block(x, reduction=16, name="se"):
    filters = x.shape[-1]
    se = tf.keras.layers.GlobalAveragePooling2D(name=f"{name}_gap")(x)
    se = tf.keras.layers.Dense(
        filters // reduction,
        activation="relu",
        use_bias=False,
        name=f"{name}_fc1",
    )(se)
    se = tf.keras.layers.Dense(
        filters,
        activation="sigmoid",
        use_bias=False,
        name=f"{name}_fc2",
    )(se)
    se = tf.keras.layers.Reshape((1, 1, filters), name=f"{name}_reshape")(se)
    x = tf.keras.layers.Multiply(name=f"{name}_scale")(x, se)
    return x

def build_model(backbone_trainable=False, unfreeze_last_n=None):
    base = tf.keras.applications.ConvNeXtTiny(
        include_top=False,
        include_preprocessing=True,
        weights=None,
        input_shape=(IMG_SIZE, IMG_SIZE, 3),
        pooling=None,
    )

    base.trainable = False

    if backbone_trainable and (unfreeze_last_n is not None):

```

```

    for layer in base.layers[-unfreeze_last_n:]:
        layer.trainable = True

inputs = tf.keras.Input(shape=(IMG_SIZE, IMG_SIZE, 3), name="input_image")
x = base(inputs, training=False)
x = squeeze_excite_block(x, reduction=16, name="se_block")
x = tf.keras.layers.GlobalAveragePooling2D(name="global_avg_pool")(x)
x = tf.keras.layers.Dense(128, activation="relu", name="dense_128")(x)
x = tf.keras.layers.Dropout(0.5, name="dropout")(x)
outputs = tf.keras.layers.Dense(1, activation="sigmoid", name="pred")(x)

model = tf.keras.Model(inputs, outputs, name="lesion_convnexttiny_bin")
return model, base

def load_trained_model(keras_path: str) -> tf.keras.Model:
    print("Rebuilding model architecture...")
    model, _ = build_model(backbone_trainable=False, unfreeze_last_n=None)

    print(f"Loading weights from {keras_path} ...")
    model.load_weights(keras_path)

    return model

def main():
    print("Reconstructing model from .keras (weights only)...")
    model = load_trained_model(MODEL_PATH)
    model.summary()

    print("\nExporting model_fp32.tflite ...")
    converter = tf.lite.TFLiteConverter.from_keras_model(model)
    tflite_fp32 = converter.convert()
    with open("model_fp32.tflite", "wb") as f:
        f.write(tflite_fp32)

```

```

print("\nExporting model_dynamic.tflite ...")
converter = tf.lite.TFLiteConverter.from_keras_model(model)
converter.optimizations = [tf.lite.Optimize.DEFAULT]
tflite_dynamic = converter.convert()
with open("model_dynamic.tflite", "wb") as f:
    f.write(tflite_dynamic)

print("\nExporting model_fp16.tflite ...")
converter = tf.lite.TFLiteConverter.from_keras_model(model)
converter.optimizations = [tf.lite.Optimize.DEFAULT]
converter.target_spec.supported_types = [tf.float16]
tflite_fp16 = converter.convert()
with open("model_fp16.tflite", "wb") as f:
    f.write(tflite_fp16)

print("\nDone. Generated:")
print(" - model_fp32.tflite")
print(" - model_dynamic.tflite")
print(" - model_fp16.tflite")

if __name__ == "__main__":
    main()

```

Search Zones

```

import os
import random
import numpy as np
import pandas as pd
from PIL import Image

```

```

import tensorflow as tf

from sklearn.model_selection import StratifiedShuffleSplit

HAM_IMAGES_DIR = r"C:\MelanomaCheckApp\ModelTrain\dataverse_files\merged"
HAM_METADATA_CSV = r"C:\MelanomaCheckApp\ModelTrain\dataverse_files\HAM10000_metadata.csv"
TFLITE_MODEL_PATH = r"E:\Downloads\melanoma_binary_pipeline\lesion_convnexttiny_best_1762112837.tflite"

IMG_SIZE = 256
RANDOM_SEED = 1337

MALIGNANT_SET = {"akiec", "bcc", "mel"}
BENIGN_SET = {"bkl", "nv", "vasc", "df"}

T_HIGH = 0.795

MAX_MALIGNANT_FRAC = 0.01

random.seed(RANDOM_SEED)
np.random.seed(RANDOM_SEED)

def dx_to_binlabel(dx: str) -> int:
    if dx in MALIGNANT_SET:
        return 1
    if dx in BENIGN_SET:
        return 0
    raise ValueError(f"Unknown dx {dx}")

def center_crop_square(pil_img: Image.Image) -> Image.Image:
    w, h = pil_img.size
    side = min(w, h)
    left = (w - side) // 2
    top = (h - side) // 2

```

```

return pil_img.crop((left, top, left + side, top + side))

def load_process_image(path):
    img = Image.open(path).convert("RGB")
    img = center_crop_square(img)
    img = img.resize((IMG_SIZE, IMG_SIZE), Image.BILINEAR)
    arr = np.asarray(img, dtype=np.float32)
    return arr

def rebuild_val_split():
    meta = pd.read_csv(HAM_METADATA_CSV)
    meta = meta[["image_id", "dx"].copy()
    meta["label_bin"] = meta["dx"].apply(dx_to_binlabel)

    meta["exists"] = meta["image_id"].apply(
        lambda iid: os.path.exists(os.path.join(HAM_IMAGES_DIR, f"{iid}.jpg"))
    )
    df_full = meta[meta["exists"]].reset_index(drop=True)

    splitter = StratifiedShuffleSplit(
        n_splits=1, test_size=0.2, random_state=RANDOM_SEED
    )
    _, val_idx = next(splitter.split(df_full, df_full["label_bin"]))
    df_val = df_full.iloc[val_idx].reset_index(drop=True)
    return df_val

def run_tflite_on_val(df_val):
    interpreter = tf.lite.Interpreter(model_path=TFLITE_MODEL_PATH)
    interpreter.allocate_tensors()
    input_details = interpreter.get_input_details()
    output_details = interpreter.get_output_details()
    input_index = input_details[0]["index"]
    output_index = output_details[0]["index"]

```

```

y_true = []
y_prob = []

n = len(df_val)
print("Running TFLite on val...")
for i, row in df_val.iterrows():
    img_id = row["image_id"]
    label = int(row["label_bin"])

    img_path = os.path.join(HAM_IMAGES_DIR, f"{img_id}.jpg")
    arr = load_process_image(img_path)
    input_data = np.expand_dims(arr, axis=0)

    interpreter.set_tensor(input_index, input_data)
    interpreter.invoke()
    output_data = interpreter.get_tensor(output_index)
    prob = float(output_data.reshape(-1)[0])

    y_true.append(label)
    y_prob.append(prob)

    if (i + 1) % 200 == 0 or (i + 1) == n:
        print(f" {i+1}/{n}", end="\r")

print("\nDone.")
return np.array(y_true, int), np.array(y_prob, float)

def main():
    df_val = rebuild_val_split()
    y_true, y_prob = run_tflite_on_val(df_val)

    total_malignant = int((y_true == 1).sum())

```

```

print("Total malignant in val:", total_malignant)

best_t_low = None
best_n_low = -1
best_stats = None

for t_low in np.linspace(0.05, T_HIGH - 0.05, 50):
    low_mask = y_prob <= t_low
    n_low = int(low_mask.sum())
    if n_low == 0:
        continue

    y_low = y_true[low_mask]
    malignant_in_low = int((y_low == 1).sum())

    malignant_frac = malignant_in_low / (total_malignant + 1e-8)

    if malignant_frac <= MAX_MALIGNANT_FRAC:
        if n_low > best_n_low:
            best_n_low = n_low
            best_t_low = float(t_low)
            best_stats = dict(
                n_low=n_low,
                malignant_in_low=malignant_in_low,
                malignant_frac=malignant_frac,
            )

print(
    "\n==== Relaxed search for T_LOW (malignant fraction <= "
    f"{MAX_MALIGNANT_FRAC:.3f}) ===="
)

if best_t_low is None:

```

```

    print("No T_LOW found under this constraint. Try increasing MAX_MALIGNANT_FRAC a
bit.")
    return

print(f"T_LOW: {best_t_low:.3f}, T_HIGH: {T_HIGH:.3f}")
print("Low zone stats:", best_stats)

low_mask = y_prob <= best_t_low
high_mask = y_prob >= T_HIGH
mid_mask = ~(low_mask | high_mask)

def zone_info(mask, name):
    n = int(mask.sum())
    if n == 0:
        return dict(zone=name, n=0)
    y_zone = y_true[mask]
    return dict(
        zone=name,
        n=n,
        malignant=int((y_zone == 1).sum()),
        benign=int((y_zone == 0).sum()),
        malignant_frac=float((y_zone == 1).mean()),
    )

low_info = zone_info(low_mask, "low")
mid_info = zone_info(mid_mask, "mid")
high_info = zone_info(high_mask, "high")

print("\nLow-risk zone (prob <= T_LOW):", low_info)
print("Mid / uncertain zone:", mid_info)
print("High-risk zone (prob >= T_HIGH):", high_info)
if __name__ == "__main__":
    main()

```

ΠΑΡΑΡΤΗΜΑ Β : Κώδικας Frontend

Home Screen

```
import 'dart:io';
import 'package:flutter/material.dart';
import 'package:image_picker/image_picker.dart';
import 'result_screen.dart';
import 'loading_screen.dart';
import 'package:image_cropper/image_cropper.dart';
import '../utils/image_analysis.dart';
import 'dart:ui' as ui;

class MelanomaCheckHome extends StatefulWidget {
  @override
  _MelanomaCheckHomeState createState() => _MelanomaCheckHomeState();
}

class _MelanomaCheckHomeState extends State<MelanomaCheckHome>
  with TickerProviderStateMixin {
  static bool _hasShownCropHintThisSession = false;

  File? _selectedImage;
  double? _imageWidth;
  double? _imageHeight;

  Future<bool> _showCropHintBottomSheet() async {
    if (_hasShownCropHintThisSession) {
      return true;
    }

    final result = await showModalBottomSheet<bool>(
      context: context,
      shape: const RoundedRectangleBorder(
        borderRadius: BorderRadius.vertical(top: Radius.circular(16)),
      ),
      builder: (context) {
        return Padding(
          padding: const EdgeInsets.fromLTRB(16, 12, 16, 24),
          child: Column(
            mainAxisAlignment: MainAxisAlignment.min,
            children: [
              Container(
                width: 40,
                height: 4,
```

```

margin: const EdgeInsets.only(bottom: 12),
decoration: BoxDecoration(
  color: Colors.grey.shade400,
  borderRadius: BorderRadius.circular(999),
),
),
Row(
  children: const [
    Icon(Icons.info_outline, color: Color(0xFF1976D2)),
    SizedBox(width: 8),
    Text(
      'Crop tip',
      style: TextStyle(
        fontSize: 16,
        fontWeight: FontWeight.w600,
      ),
    ),
  ],
),
const SizedBox(height: 8),
const Text(
  'Drag the corners to frame a single lesion and keep it centered for better analysis. '
  'Make sure no other moles or skin lesions are visible in the image.',
  style: TextStyle(fontSize: 14),
),
const SizedBox(height: 16),
SizedBox(
  width: double.infinity,
  child: ElevatedButton(
    style: ElevatedButton.styleFrom(
      backgroundColor: Color(0xFF1976D2),
      shape: RoundedRectangleBorder(
        borderRadius: BorderRadius.circular(10),
      ),
    ),
    onPressed: () => Navigator.pop(context, true),
    child: const Text(
      'Got it, crop image',
      style: TextStyle(color: Colors.white),
    ),
  ),
),
],
),
);
},

```

```

);

final didAccept = result ?? false;
if (didAccept) {
  _hasShownCropHintThisSession = true;
}
return didAccept;
}

Future<void> _pickImage(ImageSource source) async {
  final picked = await ImagePicker().pickImage(source: source);
  if (picked == null) return;

  final proceed = await _showCropHintBottomSheet();
  if (!proceed) return;

  final CroppedFile? cropped = await ImageCropper().cropImage(
    sourcePath: picked.path,
    uiSettings: [
      AndroidUiSettings(
        toolbarTitle: 'Adjust crop',
        toolbarColor: Color(0xFF1976D2),
        toolbarWidgetColor: Colors.white,
        backgroundColor: Colors.black,
        activeControlsWidgetColor: Color(0xFF1976D2),
        hideBottomControls: true,
        showCropGrid: true,
        lockAspectRatio: false,
      ),
      IOSUiSettings(
        title: 'Adjust crop',
        rotateButtonsHidden: true,
        resetButtonHidden: true,
        aspectRatioPickerButtonHidden: true,
      ),
    ],
  );

  if (cropped == null) {
    if (!mounted) return;
    ScaffoldMessenger.of(context).showSnackBar(
      const SnackBar(
        content: Text('Crop cancelled. Tap the button again to try cropping the lesion.'),
      ),
    );
  }
  return;
}

```

```

}

final imgFile = File(cropped.path);

if (!mounted) return;
final result = await Navigator.push(
  context,
  MaterialPageRoute(
    builder: (_) => LoadingScreenWithAnalysis(imageFile: imgFile),
  ),
);

if (!mounted || result == null) return;

final bytes = await imgFile.readAsBytes();
final decoded = await decodeImageFromList(bytes);

setState() {
  _selectedImage = imgFile;
  _imageWidth = decoded.width.toDouble();
  _imageHeight = decoded.height.toDouble();
});

if (result['status'] == 'fail') {
  showDialog(
    context: context,
    builder: (_) => AlertDialog(
      title: const Text('Invalid Image'),
      content: Text(result['message']),
      actions: [
        TextButton(
          onPressed: () => Navigator.pop(context),
          child: const Text('OK'),
        ),
      ],
    ),
  );
} else if (result['status'] == 'success') {
  Navigator.push(
    context,
    MaterialPageRoute(
      builder: (_) => ResultScreen(result: result['data']),
    ),
  );
}
}
}

```

```

@override
Widget build(BuildContext context) {
  final blueColor = Color(0xFF1976D2);
  final maxImageHeight = 350.0;
  final maxImageWidth = MediaQuery.of(context).size.width - 80;

  double displayedWidth = maxImageWidth;
  double displayedHeight = maxImageHeight;

  if (_imageWidth != null && _imageHeight != null) {
    final aspectRatio = _imageWidth! / _imageHeight!;
    if (aspectRatio > 1) {
      displayedWidth = maxImageWidth;
      displayedHeight = displayedWidth / aspectRatio;
    } else {
      displayedHeight = maxImageHeight;
      displayedWidth = displayedHeight * aspectRatio;
    }
  }
}

return Scaffold(
  appBar: AppBar(
    backgroundColor: blueColor,
    centerTitle: true,
    title: Text(
      'Melanoma Check',
      style: TextStyle(
        fontSize: 24,
        fontWeight: FontWeight.w900,
        color: Colors.white,
        fontFamily: 'Roboto',
      ),
    ),
  ),
  body: Stack(
    children: [
      Container(
        decoration: BoxDecoration(
          gradient: RadialGradient(
            center: Alignment.center,
            radius: 0.8,
            colors: [
              Colors.transparent,
              Colors.black.withOpacity(0.25),
            ],
          ),
        ),
      ],
    ),
  ),
);

```

```

    stops: [0.7, 1],
  ),
),
),
Center(
  child: AnimatedPadding(
    padding: EdgeInsets.only(
      top: _selectedImage != null ? 10 : 60,
      left: 24,
      right: 24,
      bottom: 24,
    ),
    duration: Duration(milliseconds: 500),
    curve: Curves.easeInOut,
    child: AnimatedSize(
      duration: Duration(milliseconds: 400),
      curve: Curves.easeInOut,
      child: Container(
        margin: EdgeInsets.all(16),
        padding: EdgeInsets.all(16),
        decoration: BoxDecoration(
          color: Colors.white,
          border: Border.all(color: blueColor, width: 3),
          borderRadius: BorderRadius.circular(16),
          boxShadow: [
            BoxShadow(
              color: blueColor.withOpacity(0.3),
              blurRadius: 12,
              spreadRadius: 1,
            ),
          ],
        ),
        child: Column(
          mainAxisAlignment: MainAxisAlignment.min,
          children: [
            Text(
              'Upload or take a picture to analyze your skin lesion.',
              style: TextStyle(fontSize: 16),
              textAlign: TextAlign.center,
            ),
            SizedBox(height: 8),
            Text(
              'For best results, make sure the lesion is close up, centered in the image, and well lit.',
              style: TextStyle(
                fontSize: 12,
                fontWeight: FontWeight.w300,

```

```

        color: Colors.black54,
      ),
      textAlign: TextAlign.center,
    ),
    SizedBox(height: 24),
    Container(
      decoration: BoxDecoration(
        border: Border.all(color: blueColor, width: 2),
        borderRadius: BorderRadius.circular(8),
      ),
      child: ElevatedButton.icon(
        icon: Icon(Icons.photo_library, color: blueColor),
        label: Text(
          'Upload from Gallery',
          style: TextStyle(
            color: blueColor,
            fontWeight: FontWeight.bold,
          ),
        ),
        style: ElevatedButton.styleFrom(
          backgroundColor: Colors.white,
          minimumSize: Size(double.infinity, 50),
          elevation: 0,
          shape: RoundedRectangleBorder(
            borderRadius: BorderRadius.circular(8),
          ),
        ),
        onPressed: () => _pickImage(ImageSource.gallery),
      ),
    ),
    SizedBox(height: 16),
    Container(
      decoration: BoxDecoration(
        border: Border.all(color: blueColor, width: 2),
        borderRadius: BorderRadius.circular(8),
      ),
      child: ElevatedButton.icon(
        icon: Icon(Icons.camera_alt, color: blueColor),
        label: Text(
          'Take a Picture',
          style: TextStyle(color: blueColor),
        ),
        style: ElevatedButton.styleFrom(
          backgroundColor: Colors.white,
          minimumSize: Size(double.infinity, 50),
          elevation: 0,

```

```

        shape: RoundedRectangleBorder(
          borderRadius: BorderRadius.circular(8),
        ),
      ),
      onPressed: () => _pickImage(ImageSource.camera),
    ),
  ),
  if (_selectedImage != null) ...[
    SizedBox(height: 24),
    ClipRRect(
      borderRadius: BorderRadius.circular(12),
      child: Image.file(
        _selectedImage!,
        width: displayedWidth,
        height: displayedHeight,
        fit: BoxFit.cover,
      ),
    ),
  ],
),
),
),
),
),
),
],
),
);
}
}

```

Loading Screen

```

import 'dart:io';
import 'package:flutter/material.dart';
import 'package:melanomacheckapp/services/inference_service.dart';
import '../utils/image_analysis.dart';

class LoadingScreen extends StatefulWidget {
  const LoadingScreen({super.key});

  @override
  State<LoadingScreen> createState() => _LoadingScreenState();
}

```

```

class _LoadingScreenState extends State<LoadingScreen>
  with SingleTickerProviderStateMixin {
  late final AnimationController _controller;
  late final Animation<double> _scaleAnimation;

  @override
  void initState() {
    super.initState();
    _controller = AnimationController(
      vsync: this,
      duration: const Duration(seconds: 1),
    )..repeat(reverse: true);

    _scaleAnimation = Tween<double>(begin: 0.8, end: 1.2).animate(
      CurvedAnimation(parent: _controller, curve: Curves.easeInOut),
    );
  }

  @override
  void dispose() {
    _controller.dispose();
    super.dispose();
  }

  @override
  Widget build(BuildContext context) {
    const totalDots = 3;
    return Scaffold(
      backgroundColor: Colors.white,
      body: Center(
        child: Column(
          mainAxisAlignment: MainAxisAlignment.center,
          children: [
            ScaleTransition(
              scale: _scaleAnimation,
              child: const Icon(Icons.search, size: 100, color: Colors.blue),
            ),
            const SizedBox(height: 20),
            Row(
              mainAxisAlignment: MainAxisAlignment.center,
              children: List.generate(
                totalDots,
                (index) => Container(
                  width: 12,
                  height: 12,

```

```

        margin: const EdgeInsets.symmetric(horizontal: 4),
        decoration: const BoxDecoration(
          color: Colors.blue,
          shape: BoxShape.circle,
        ),
      ),
    ),
  ],
),
);
}
}

class LoadingScreenWithAnalysis extends StatefulWidget {
  final File imageFile;
  const LoadingScreenWithAnalysis({super.key, required this.imageFile});

  @override
  State<LoadingScreenWithAnalysis> createState() =>
    _LoadingScreenWithAnalysisState();
}

class _LoadingScreenWithAnalysisState extends State<LoadingScreenWithAnalysis> {
  @override
  void initState() {
    super.initState();
    WidgetsBinding.instance.addPostFrameCallback((_) => _analyzeImage());
  }

  Future<void> _analyzeImage() async {
    try {
      final analysisResult = await analyzeImage(widget.imageFile);
      await Future.delayed(const Duration(milliseconds: 300));

      final isClear = analysisResult['clear'] == true;
      final hasSkin = analysisResult['skin'] == true;

      if (!isClear || !hasSkin) {
        if (!mounted) return;
        Navigator.pop(context, {
          'status': 'fail',
          'message': !isClear
            ? 'Image is not clear enough.'
            : 'Image does not contain enough skin.',
        });
      }
    }
  }
}

```

```

    });
    return;
}

InferenceService service;
try {
    service = await InferenceService.create(
        modelAsset: 'assets/model_fp16.tflite',
        labelsAsset: 'assets/labels.txt',
        altModelAsset: 'assets/model_fp16.tflite',
    );
} catch (e) {
    if (!mounted) return;
    Navigator.pop(context, {
        'status': 'fail',
        'message': 'Model/labels load failed: $e',
    });
    return;
}

try {
    final raw = await service.run(widget.imageFile);
    service.close();

    if (!mounted) return;

    print('DEBUG raw inference: $raw');

    double conf = 0.0;

    if (raw is Map) {
        final dynamic cVal = raw['confidence'];

        if (cVal is num) {
            conf = cVal.toDouble();
            if (conf > 1.0) {
                conf = conf / 100.0;
            }
        } else if (cVal is String) {
            var s = cVal.trim();
            if (s.endsWith('%')) {
                s = s.substring(0, s.length - 1);
            }
            final parsed = double.tryParse(s);
            if (parsed != null) {
                conf = parsed;
            }
        }
    }
}

```

```

        if (conf > 1.0) {
            conf = conf / 100.0;
        }
    } else if (raw['scores'] is List &&
        (raw['scores'] as List).isEmpty) {
        final first = (raw['scores'] as List).first;
        if (first is num) {
            conf = first.toDouble();
        }
    }
}

conf = conf.clamp(0.0, 1.0);

Navigator.pop(context, {
    'status': 'success',
    'data': {
        'confidence': conf,
        'raw': raw,
    },
});
} catch (e) {
    service.close();
    if (!mounted) return;
    Navigator.pop(context, {
        'status': 'fail',
        'message': 'Inference failed: $e',
    });
}
} catch (e) {
    if (!mounted) return;
    Navigator.pop(context, {
        'status': 'fail',
        'message': 'Pre-check failed: $e',
    });
}
}

@override
Widget build(BuildContext context) {
    return const LoadingScreen();
}
}

```

Result Screen

```
import 'dart:ui';
import 'dart:async';
import 'package:flutter/material.dart';
import 'home_screen.dart';

class ResultScreen extends StatefulWidget {
  final Map<String, dynamic> result;
  const ResultScreen({required this.result});

  @override
  _ResultScreenState createState() => _ResultScreenState();
}

class _ResultScreenState extends State<ResultScreen>
  with TickerProviderStateMixin {
  static const double kThresholdHighRisk = 0.60;
  static const double kThresholdElevated = 0.300;

  late AnimationController _glassController;
  late Animation<double> _scaleAnimation;
  late Animation<double> _blurAnimation;

  late AnimationController _pulseController;
  late Animation<double> _pulseAnimation;
  String? _lastPulseLevel;

  String _headlineText = "";
  String displayedText = "";
  int _currentIndex = 0;

  String _safetyPrefixFull = "";
  String _safetyRestFull = "";
  String _safetyPrefixShown = "";
  bool _safetyShowFull = false;
  int _safetyPrefixIndex = 0;
  Timer? _safetyTimer;
  double? _safetyReservedHeight;
  bool _safetyPrepared = false;

  static const String footerDisclaimer =
    "This app provides information only and does not diagnose or replace professional medical
    advice.";
```

```

@Override
void initState() {
  super.initState();

  _glassController = AnimationController(
    vsync: this,
    duration: const Duration(seconds: 2),
  );
  _scaleAnimation = Tween<double>(begin: 0.8, end: 1.5).animate(
    CurvedAnimation(parent: _glassController, curve: Curves.easeInOut),
  );
  _blurAnimation = Tween<double>(begin: 0, end: 20).animate(
    CurvedAnimation(parent: _glassController, curve: Curves.easeInOut),
  );
  _glassController.forward();

  _pulseController =
    AnimationController(vsync: this, duration: const Duration(milliseconds: 1200));
  _pulseAnimation = const AlwaysStoppedAnimation(1.0);

  final prob = _toProb(widget.result['confidence']);
  final level = _levelFromProb(prob);
  _headlineText = _headlineFromLevel(level);

  _animateDiagnosis();

  WidgetsBinding.instance.addPostFrameCallback((_) {
    _prepareSafetyTextAndReserveSpace();
  });
}

@Override
void dispose() {
  _glassController.dispose();
  _pulseController.dispose();
  _safetyTimer?.cancel();
  super.dispose();
}

double _toProb(dynamic v) {
  if (v is num) {
    final p = v.toDouble();
    return p > 1.0 ? (p / 100.0).clamp(0.0, 1.0) : p.clamp(0.0, 1.0);
  }
  if (v is String) {
    var s = v.trim();

```

```

    if (s.endsWith('%')) s = s.substring(0, s.length - 1);
    final val = double.tryParse(s);
    if (val != null) {
        return val > 1.0 ? (val / 100.0).clamp(0.0, 1.0) : val.clamp(0.0, 1.0);
    }
}
return 0.0;
}

```

```

String _levelFromProb(double p) {
    if (p < 0.0 || p.isNaN) return 'indeterminate';

    if (p >= kThresholdHighRisk) return 'critical';
    if (p >= kThresholdElevated) return 'high';
    return 'low';
}

```

```

String _riskLabelFromLevel(String level) {
    switch (level) {
        case 'critical':
            return "Risk level: High";
        case 'high':
            return "Risk level: Elevated";
        case 'low':
            return "Risk level: Lower";
        default:
            return "Risk level: Indeterminate";
    }
}

```

```

String _headlineFromLevel(String level) {
    switch (level) {
        case 'critical':
            return "High-risk pattern detected";
        case 'high':
            return "Elevated-risk pattern detected";
        case 'low':
            return "Lower-risk pattern detected";
        default:
            return "Result could not be interpreted";
    }
}

```

```

Color _glassColor(String level) {
    switch (level) {
        case 'critical':

```

```

    return Colors.red.shade700;
case 'high':
    return Colors.orange;
case 'low':
    return Colors.blueAccent;
default:
    return Colors.grey;
}
}

TextSpan _buildSafetyRichSpan(String level, String prefix, String rest) {
  final prefixColor = (level == 'high') ? Colors.orange : Colors.black54;
  return TextSpan(children: [
    TextSpan(
      text: prefix,
      style: TextStyle(
        fontSize: 16,
        color: prefixColor,
        fontWeight: FontWeight.w600,
      ),
    ),
    TextSpan(
      text: rest,
      style: const TextStyle(fontSize: 16, color: Colors.black54),
    ),
  ]);
}

void _composeSafetyText() {
  final prob = _toProb(widget.result['confidence']);
  final level = _levelFromProb(prob);

  if (level == 'critical') {
    _safetyPrefixFull = "High risk: ";
    _safetyRestFull =
      "This result suggests features that can be seen in serious skin conditions. "
      "Please arrange an in-person assessment with a dermatologist as soon as possible.";
  } else if (level == 'high') {
    _safetyPrefixFull = "Elevated risk: ";
    _safetyRestFull =
      "Some features appear concerning. We recommend booking a dermatology appointment "
      "for a proper examination.";
  } else if (level == 'low') {
    _safetyPrefixFull = "Lower risk: ";
    _safetyRestFull =
      "The model did not find strong high-risk features, but this does not rule out skin cancer. "

```

```

        "If you are worried, notice changes, or have symptoms, please consult a clinician.";
    } else {
        _safetyPrefixFull = "Result unavailable: ";
        _safetyRestFull =
            "The system could not confidently assess this image. "
            "Please repeat the photo or consult a clinician for an in-person examination.";
    }
}

```

```

void _animateDiagnosis() {
    Future.delayed(const Duration(milliseconds: 50), () {
        if (!mounted) return;
        if (_currentIndex < _headlineText.length) {
            setState(() {
                displayedText += _headlineText[_currentIndex];
                _currentIndex++;
            });
            _animateDiagnosis();
        }
    });
}

```

```

void _prepareSafetyTextAndReserveSpace() {
    if (_safetyPrepared) return;
    _composeSafetyText();

    final width = MediaQuery.of(context).size.width - 32;
    final prob = _toProb(widget.result['confidence']);
    final level = _levelFromProb(prob);
    final fullSpan = _buildSafetyRichSpan(level, _safetyPrefixFull, _safetyRestFull);

    final tp = TextPainter(
        text: fullSpan,
        textDirection: TextDirection.ltr,
        maxLines: null,
    )..layout(maxWidth: width);

    setState(() {
        _safetyReservedHeight = tp.size.height;
        _safetyPrepared = true;
    });

    _startSafetyPrefixTyping();
}

```

```

void _startSafetyPrefixTyping() {

```

```

if (_safetyPrefixFull.isEmpty || _safetyTimer != null) return;
const step = Duration(milliseconds: 18);
_safetyTimer = Timer.periodic(step, (t) {
  if (!mounted) return;
  if (_safetyPrefixIndex >= _safetyPrefixFull.length) {
    t.cancel();
    _safetyTimer = null;
    Future.delayed(const Duration(milliseconds: 250), () {
      if (!mounted) return;
      setState(() => _safetyShowFull = true);
    });
    return;
  }
  setState(() {
    _safetyPrefixShown += _safetyPrefixFull[_safetyPrefixIndex];
    _safetyPrefixIndex++;
  });
});
}

void _applyPulseForLevel(String level) {
  if (_lastPulseLevel == level) return;
  _lastPulseLevel = level;
  _pulseController.stop();

  if (level == 'high') {
    _pulseController.duration = const Duration(milliseconds: 1200);
    _pulseAnimation = Tween<double>(begin: 0.97, end: 1.03).animate(
      CurvedAnimation(parent: _pulseController, curve: Curves.easeInOut),
    );
    _pulseController.repeat(reverse: true);
  } else if (level == 'critical') {
    _pulseController.duration = const Duration(milliseconds: 1100);
    _pulseAnimation = Tween<double>(begin: 0.95, end: 1.05).animate(
      CurvedAnimation(parent: _pulseController, curve: Curves.easeInOut),
    );
    _pulseController.repeat(reverse: true);
  } else {
    _pulseAnimation = const AlwaysStoppedAnimation(1.0);
  }
}

void _navigateToHome() async {
  await Future.delayed(const Duration(milliseconds: 500));
  if (!mounted) return;
  Navigator.of(context).pushAndRemoveUntil(

```

```

PageRouteBuilder(
  pageBuilder: (context, animation, secondaryAnimation) => MelanomaCheckHome(),
  transitionsBuilder: (context, animation, secondaryAnimation, child) {
    final curved =
      CurvedAnimation(parent: animation, curve: Curves.easeInOutCubic);
    final slide = Tween<Offset>(
      begin: const Offset(-1.1, 0.0),
      end: Offset.zero,
    ).animate(curved);
    final fade = Tween<double>(begin: 0.6, end: 1.0).animate(curved);
    return SlideTransition(
      position: slide,
      child: FadeTransition(opacity: fade, child: child),
    );
  },
),
(route) => false,
);
}

```

@override

```

Widget build(BuildContext context) {
  final blueColor = const Color(0xFF1976D2);
  final glassSize = 100.0;

  final prob = _toProb(widget.result['confidence']);
  final level = _levelFromProb(prob);
  final glassColor = _glassColor(level);
  final riskLabel = _riskLabelFromLevel(level);

  _applyPulseForLevel(level);

  return Scaffold(
    appBar: AppBar(
      backgroundColor: blueColor,
      centerTitle: true,
      title: const Text(
        'Analysis Result',
        style: TextStyle(
          fontSize: 24,
          fontWeight: FontWeight.w900,
          color: Colors.white,
          fontFamily: 'Roboto',
        ),
      ),
    ),
  ),
),

```

```

body: Center(
  child: Stack(
    alignment: Alignment.center,
    children: [
      AnimatedBuilder(
        animation: Listenable.merge([_glassController, _pulseController]),
        builder: (context, child) {
          return Transform.scale(
            scale: _scaleAnimation.value * _pulseAnimation.value,
            child: BackdropFilter(
              filter: ImageFilter.blur(
                sigmaX: _blurAnimation.value,
                sigmaY: _blurAnimation.value,
              ),
              child: Opacity(
                opacity: 0.15,
                child: Icon(
                  Icons.search,
                  size: glassSize,
                  color: glassColor,
                ),
              ),
            ),
          );
        },
      ),
      Column(
        mainAxisAlignment: MainAxisAlignment.min,
        mainAxisSize: MainAxisSize.min,
        children: [
          Text(
            displayedText,
            style: const TextStyle(
              fontSize: 28,
              fontWeight: FontWeight.bold,
              color: Colors.black87,
            ),
            textAlign: TextAlign.center,
          ),
          const SizedBox(height: 12),
          if (_currentIndex == _headlineText.length) ...[
            Text(
              riskLabel,
              style: const TextStyle(
                fontSize: 18,
                color: Colors.black87,
              ),
            ),
          ],
        ],
      ),
    ],
  ),
),

```

```

        fontWeight: FontWeight.w600,
      ),
      textAlign: TextAlign.center,
    ),
    const SizedBox(height: 4),
  ],
],
),
],
),
),
),
),
bottomNavigationBar: SafeArea(
  child: Padding(
    padding: const EdgeInsets.all(16.0),
    child: Column(
      mainAxisAlignment: MainAxisAlignment.min,
      children: [
        if (_safetyPrepared)
          SizedBox(
            height: _safetyReservedHeight ?? 64,
            child: Align(
              alignment: Alignment.center,
              child: RichText(
                textAlign: TextAlign.center,
                text: _safetyShowFull
                  ? _buildSafetyRichSpan(
                      level,
                      _safetyPrefixFull,
                      _safetyRestFull,
                    )
                  : _buildSafetyRichSpan(
                      level,
                      _safetyPrefixShown.isEmpty
                        ? ''
                        : _safetyPrefixShown,
                    ),
                ),
              ),
            ),
          ),
        const SizedBox(height: 8),
        Text(
          _footerDisclaimer,
          textAlign: TextAlign.center,
          style: TextStyle(
            fontSize: 13,

```

```

        color: Colors.black.withOpacity(0.6),
        height: 1.2,
    ),
),
const SizedBox(height: 12),
SizedBox(
  width: double.infinity,
  child: ElevatedButton(
    onPressed: _navigateToHome,
    child: const Text('Try Again'),
    style: ElevatedButton.styleFrom(
      backgroundColor: blueColor,
      foregroundColor: Colors.white,
      padding: const EdgeInsets.symmetric(vertical: 14),
      textStyle: const TextStyle(fontSize: 18),
    ).copyWith(
      overlayColor:
        MaterialStateProperty.resolveWith<Color?>((states) {
          return states.contains(MaterialState.pressed)
            ? Colors.grey.shade400
            : null;
        })
    ),
  ),
),
),
],
),
),
);
}
}

```

Image_analysis

```
import 'dart:io';
import 'package:image/image.dart' as img;

const double kSharpnessThresholdSkin = 25.0;
const double kSharpnessThresholdNonSkin = 60.0;
const double kSkinRatioThreshold = 0.15;

bool _isSkinPixel(int r, int g, int b) {
  final maxC = [r, g, b].reduce((a, b) => a > b ? a : b);
  final minC = [r, g, b].reduce((a, b) => a < b ? a : b);
  final diff = maxC - minC;

  final basicSkin =
    r > 80 &&
      g > 30 &&
      b > 15 &&
      (r - g).abs() > 5 &&
      r >= g &&
      r >= b;

  final lightSkin =
    maxC > 200 &&
      diff > 5 &&
      r >= g &&
      r >= b;

  return basicSkin || lightSkin;
}

Future<Map<String, dynamic>> analyzeImage(File imageFile) async {
  try {
    final bytes = await imageFile.readAsBytes();
    final decoded = img.decodeImage(bytes);
    if (decoded == null || decoded.width < 3 || decoded.height < 3) {
      return {'clear': false, 'skin': false, 'skinRatio': 0.0};
    }

    final resized = img.copyResize(decoded, width: 200);

    double sharpness = 0;
    for (int y = 1; y < resized.height - 1; y++) {
      for (int x = 1; x < resized.width - 1; x++) {
        final pLeft = resized.getPixel(x - 1, y);
```

```

    final pRight = resized.getPixel(x + 1, y);
    final pUp = resized.getPixel(x, y - 1);
    final pDown = resized.getPixel(x, y + 1);

    final gx = pRight.r - pLeft.r;
    final gy = pDown.r - pUp.r;

    sharpness += (gx * gx + gy * gy).toDouble();
  }
}

final normalizedSharpness = sharpness / (resized.width * resized.height);

int skinPixels = 0;
int totalPixels = 0;

for (int y = 0; y < resized.height; y += 2) {
  for (int x = 0; x < resized.width; x += 2) {
    totalPixels++;
    final pixel = resized.getPixel(x, y);
    final int r = pixel.r.toInt();
    final int g = pixel.g.toInt();
    final int b = pixel.b.toInt();

    if (_isSkinPixel(r, g, b)) {
      skinPixels++;
    }
  }
}

final skinRatio = totalPixels > 0 ? skinPixels / totalPixels : 0.0;
final isSkin = skinRatio > kSkinRatioThreshold;

final double sharpnessThreshold =
isSkin ? kSharpnessThresholdSkin : kSharpnessThresholdNonSkin;

final isClear = normalizedSharpness > sharpnessThreshold;

return {
  'clear': isClear,
  'skin': isSkin,
  'skinRatio': skinRatio,
  'sharpness': normalizedSharpness,
};
} catch (e) {
return {'clear': false, 'skin': false, 'skinRatio': 0.0};
}

```

| }
| }

|