

POLITECNICO DI TORINO
Laurea Magistralae in Ingegneria Biomedica



**Politecnico
di Torino**

Tesi Magistrale

**Sviluppo di un applicazione mobile basata
su una rete neurale convoluzionale per la
classificazione di Acne, Psoriasi e
Dermatite Atopica.**

Relatore

Prof. Massimo SALVI

Tutor Aziendale

Ing. Saverio MILO

Candidato

Benedetta BOCCARDI

OTTOBRE 2023

Ringraziamenti

Ringrazio il mio relatore, il professor Massimo Salvi, per essersi dimostrato sempre disponibile, interessato e pronto al supporto quando c'è n'è stato di bisogno.

Ringrazio profondamente tutto il team della Brain Technologies, ognuno di voi ha contribuito a rendere piacevole questa esperienza. In particolare ringrazio il mio responsabile, Saverio Milo, sei stato una presenza costante che mi ha supportato in tutto il percorso trasmettendomi molto.

Ringrazio i miei genitori, mia sorella e mio fratello per aver creduto in me sempre, avermi supportato in ogni mia scelta senza esprimere giudizi. So che tutti voi avete rinunciato a tanto per permettermi di realizzare i miei sogni e ve ne sarò per sempre grata.

Ringrazio Andrea, hai creduto sempre in me anche quando nemmeno io ero in grado di farlo. La tua fiducia e il tuo amore mi hanno dato la forza di affrontare tutte le sfide che mi si sono palesate. Per noi questo è solo il primo capitolo e non vedo l'ora di scoprire il futuro insieme a te. Ringrazio Caterina, la mia complice. Sei sempre stata in questi anni il mio porto sicuro, il punto fermo, colei che mi ha sempre capita, colei che voglio accanto quando va tutto bene ma anche quando va tutto male. Sei fondamentale per me e lo sarai sempre.

Ringrazio Nicola per essere stato il mio compagno di avventura. Non c'è stato un momento in tutto questo percorso in cui non ci sei stato per me. Le ore passate seduti l'uno di fronte all'altro non penso riusciremo mai a quantificarle. Anche quando non era necessario tu c'eri e con la tua sola presenza eri capace di donarmi serenità. L'incontrarti è stata una vera fortuna e senza di te sono più che certa che non sarei qui oggi.

Ringrazio i miei amici conosciuti per caso il primo giorno di università e che ora sono per me una seconda famiglia, in particolare Giulia, Simone, Alessia e Gabriele. In questi anni ci siamo divertiti maturando insieme (forse) e non sarebbe mai stato lo stesso senza di voi. Mi raccomando tutti pronti per la nuova stagione.

Indice

Elenco delle tabelle	VII
Elenco delle figure	VIII
1 Introduzione	1
1.1 Contesto e Obiettivo dell'elaborato	1
1.2 Organizzazione della tesi	2
2 Stato dell'arte	3
2.1 Panoramica sulle malattie della pelle selezionate	3
2.1.1 Acne	3
2.1.2 Psoriasi	5
2.1.3 Dermatite Atopica	8
2.1.4 Sintomatologia comune	10
2.2 Metodi di supporto diagnostico computer based	11
2.3 Applicazioni attualmente disponibili	12
3 Raccolta e preparazione dei dati	14
3.1 Origine e composizione del Dataset	16
3.2 Pre-elaborazione dei dati e Data Augmentation	17
3.3 Implementazione algoritmi di color constancy	20
3.3.1 Gray World	20
3.3.2 Max RGB	22
3.4 Divisione dei dati in set di addestramento e Test Set	24
4 Implementazione, addestramento e valutazione delle prestazioni dei modelli	27
4.1 Architettura della rete neurale	29
4.1.1 ResNet 50	29
4.1.2 Inception V3	29
4.1.3 MobileNet V2	30

4.2	Ambiente di sviluppo e librerie utilizzate	32
4.3	Configurazione di allenamento	33
4.4	Modelli in cascata	36
4.4.1	Implementazione algoritmo di predizione	37
4.5	Valutazione delle prestazioni	39
4.5.1	Immagini originali vs Immagini Filtrate	39
4.5.2	Valutazione delle prestazioni sulle diverse architetture di rete	43
4.5.3	Valutazione delle prestazioni del miglior modello sul Dataset di Test	44
5	Progettazione e sviluppo di ADP Skin-Assistant	45
5.1	Flutter	45
5.2	Requisiti dell'app	47
5.2.1	Interfaccia utente	47
5.3	Architettura dell'app	51
6	Risultati e conclusioni	53
6.1	Prestazioni e limitazioni dell'app e del modello	53
6.1.1	Saliency map	56
6.2	Possibili sviluppi futuri	58
6.3	Riepilogo degli obiettivi raggiunti	59
	Bibliografia	60

Elenco delle tabelle

4.1	Caratteristiche dei modelli pre-allenati	33
4.2	Categorical Accuracy relativa al Validation nelle 5 prove di divisione	37
4.3	Confronto sulla classe Psoriasi sulla base della Precision, Recall e F1-Score	40
6.1	Metriche relative al dataset di Test	54

Elenco delle figure

2.1	Le tre tipologie di acne : Mild, Moderate e Severe	4
2.2	Esempio di psoriasi a Placche, Guttata e Inversa	6
2.3	Esempio di psoriasi Pustolosa e Eritrodermica	7
2.4	Esempio di Dermatite Atopica Acuta e Sub-Acuta	9
2.5	Esempio di Dermatite Atopica Cronica e Pitiriasi Alba	9
3.1	Psoriasi Guttate proveniente da Dermnet	17
3.2	Acne proveniente da atlasDerm	17
3.3	Immagine Originale e Immagine con width shift range di 0.1	18
3.4	Immagine con height shift range di 0.1 e flippata orizzontalmente	19
3.5	Immagine flippata verticalmente	19
3.6	Dermatite Atopica Originale	21
3.7	Dermatite Atopica filtrata con Gray World	21
3.8	Dermatite Atopica Originale	23
3.9	Dermatite Atopica filtrata con Max-RGB	23
3.10	Acne proveniente da Dermis.net	26
3.11	Dermatite Atopica proveniente da Dermatoweb.net	26
4.1	Architettura MobileNetV2[43]	31
4.2	Confusion Matrix relativa alla prova 5 sul Validation	36
4.3	Immagine originale con le sue tre trasformazioni	38
4.4	Confusion Matrix immagini originali Acne	40
4.5	Confusion Matrix immagini originali Psoriasi/Dermatite Atopica	40
4.6	Confusion Matrix complessiva sulle immagini originali	41
4.7	Confusion Matrix immagini Max-RGB Acne	41
4.8	Confusion Matrix immagini Max-RGB Psoriasi/Dermatite Atopica	41
4.9	Confusion Matrix complessiva immagini Max-RGB	42
4.10	Confusion Matrix immagini Gray World Acne	42
4.11	Confusion Matrix immagini Gray-World Psoriasi/Dermatite Atopica	42
4.12	Confusion Matrix complessiva immagini Gray World	42

4.13	Confusion Matrix complessiva relativa all'architettura di rete ResNet50	43
4.14	Confusion Matrix complessiva relativa all'architettura di rete InceptionV3	43
4.15	Confusion Matrix complessiva sul Test	44
5.1	Schermata introduttiva 1 di ADP SkinAssistant	49
5.2	Schermata introduttiva 2 di ADP SkinAssistant	49
5.3	Schermata introduttiva 3 di ADP SkinAssistant	49
5.4	Schermata di avvio di ADP SkinAssistant	50
5.5	Schermata home di ADP SkinAssistant	50
5.6	Schermata home di ADP SkinAssistant post classificazione	50
6.1	Prestazioni relative allo studio effettuato dal dipartimento di dermatologia del Peking Union Medical College Hospital [48]	54
6.2	Label reale Psoriasi, label predetta Dermatite Atopica	55
6.3	Label reale Dermatite Atopica, label predetta Dermatite Atopica	55
6.4	Label reale Psoriasi, label predetta Dermatite Atopica	55
6.5	Label reale Dermatite Atopica, label predetta Dermatite Atopica	55
6.6	Esempio di Psoriasi con trademark e la sua relativa saliency map	56
6.7	Esempio di Dermatite Atopica con sfondo nero e la sua relativa saliency map	57

Capitolo 1

Introduzione

1.1 Contesto e Obiettivo dell'elaborato

Nell'attuale contesto, le malattie della pelle rappresentano uno dei problemi di salute più comuni che colpiscono le persone di tutte le età. Se non individuate e gestite tempestivamente queste malattie possono causare gravi conseguenze per la salute e oneri finanziari significativi per i pazienti. Pertanto, è di fondamentale importanza riconoscere le malattie cutanee in una fase iniziale al fine di prevenire ulteriori complicanze. Tuttavia, a causa delle diversità dei sintomi presentati l'analisi delle malattie della pelle richiede una conoscenza approfondita.

Nel corso degli anni, il settore della dermatologia ha visto importanti sviluppi tecnologici che hanno rivoluzionato l'approccio alla diagnosi e alla gestione delle malattie cutanee. Tra questi sviluppi, l'intelligenza artificiale e il machine learning hanno acquisito un ruolo di rilievo, aprendo nuove possibilità nell'ambito della diagnosi precoce e dell'assistenza ai pazienti[1].

L'obiettivo proposto dall'elaborato è la realizzazione di un'app, ***APD SkinAssistant***, che sfrutta l'intelligenza artificiale per riconoscere tre tra le malattie della pelle più diffuse al mondo: Acne, Psoriasi e Dermatite Atopica. L'applicazione non fornisce una diagnosi, che invece necessita di un dermatologo esperto, ma si prospetta l'obiettivo di un supporto al riconoscimento preventivo delle tre malattie cutanee.

Le lesioni di Acne, Psoriasi e Dermatite Atopica nelle loro forme lievi, si presentano spesso con sintomatologie molto simili, aspetto che rende il loro riconoscimento un caso di studio per nulla banale. A tal proposito, il coinvolgimento di uno strumento dotato di intelligenza artificiale con prestazioni adeguate, risulterebbe estremamente utile al riconoscimento preventivo delle tre malattie.

1.2 Organizzazione della tesi

La tesi è stata suddivisa in 6 capitoli, ciascuno dei quali affronta specifici aspetti del lavoro svolto.

Nel primo capitolo viene fornita un'introduzione al contesto e agli obiettivi del progetto, ponendo l'attenzione sull'importanza delle malattie della pelle e sull'utilizzo dell'intelligenza artificiale per il supporto alla diagnosi dermatologica.

Il secondo capitolo è dedicato allo stato dell'arte. Vengono di seguito analizzate approfonditamente le malattie della pelle prese in esame nello studio ossia l'acne, la psoriasi e la dermatite atopica. Inoltre, viene posta particolare attenzione alla sintomatologia comune. Vengono poi vagliati i metodi di supporto diagnostico *computer-based* attualmente utilizzati e le applicazioni esistenti nel campo della dermatologia digitale.

Il terzo capitolo è incentrato sulla raccolta e la preparazione dei dati, spiegando l'origine e la composizione del Dataset utilizzato per l'addestramento dei modelli. Vengono presentati anche i processi di *pre-elaborazione* dei dati e *data augmentation* insieme all'implementazione degli algoritmi di *color constancy* **Gray World** e **Max RGB** utilizzati per migliorare la coerenza cromatica delle immagini. In ultima istanza, viene descritta la suddivisione dei dati in set di addestramento e Test Set. Il quarto capitolo rappresenta il fulcro del lavoro, in cui viene presentata l'implementazione, l'addestramento e la valutazione delle prestazioni dei modelli di intelligenza artificiale. Vengono descritte le architetture delle reti neurali utilizzate, tra cui *ResNet 50*, *Inception V3* e *MobileNet V2*, insieme all'ambiente di sviluppo e alle librerie utilizzate per l'implementazione. Vengono valutate le prestazioni dei modelli sia su immagini originali che filtrate, e viene presentata la valutazione del miglior modello sul Dataset di Test.

Il quinto capitolo è dedicato alla progettazione e allo sviluppo dell'app ADP Skin-Assistant utilizzando **Flutter**, fornendo informazioni sui requisiti dell'app e sulla sua interfaccia utente. Viene inoltre presentata l'architettura dell'applicazione.

Infine, nel sesto capitolo, vengono riportati i risultati e le conclusioni del lavoro, valutando le prestazioni e le limitazioni dell'app e dei modelli implementati. Si evidenziano le possibili prospettive future per lo sviluppo del progetto riepilogando gli obiettivi raggiunti.

La bibliografia elenca le fonti utilizzate per la stesura dell'elaborato.

Capitolo 2

Stato dell'arte

2.1 Panoramica sulle malattie della pelle selezionate

2.1.1 Acne

L'acne è una malattia infiammatoria cronica dell'unità pilosebacea causata dall'aumento della produzione di sebo, un olio naturale prodotto dalle ghiandole sebacee presenti nella pelle. Gli ormoni, in particolare gli androgeni, giocano un ruolo chiave nello sviluppo dell'acne. Durante l'adolescenza, gli ormoni sessuali iniziano a essere prodotti in quantità più elevate stimolando le ghiandole sebacee a produrre più sebo; esso può mescolarsi con le cellule morte della pelle ostruendo i pori e creando un ambiente favorevole alla proliferazione batterica dei *Propionibacterium acnes*[2]. L'acne è una delle malattie della pelle più comuni caratterizzata dalla formazione di comedoni, brufoli, pustole e talvolta cisti sulla pelle. Questa condizione colpisce quasi tutti gli adolescenti tra i 15 e i 17 anni, anche se in forma lieve, mentre circa il 15-20% delle persone manifesta una forma moderata o grave[2]. La sua diffusione è così ampia che può essere considerata un'esperienza comune durante l'adolescenza, ma è sbagliato pensare che sia una malattia confinata a questo periodo di vita. L'acne, infatti, può persistere anche in età adulta causando effetti negativi sull'autostima e sulla qualità della vita delle persone colpite. Secondo il New England Journal of Medicine il 12% degli uomini e il 26% delle donne soffre di acne dopo i quarant'anni ed essi hanno una maggior probabilità di sviluppare patologie come ansia e depressione[3]. Anche se la colonizzazione precoce da parte dei *Propionibacterium acnes* e una predisposizione familiare possono svolgere un ruolo significativo nello sviluppo dell'acne, le cause precise della malattia non sono ancora completamente comprese. Ci sono alcuni fattori che vengono considerati come una sorta di *trigger* dell'acne: la dieta, ma al momento non esistono evidenze

scientifiche sufficienti per dimostrare una correlazione diretta tra la dieta e l'insorgenza dell'acne. Pertanto, mentre alcuni fattori possono influenzare la gravità e il decorso della malattia è ancora necessaria ulteriore ricerca per comprendere appieno le cause dell'acne e l'efficacia dei diversi trattamenti disponibili. Attualmente, non esiste un trattamento universale o ideale per l'acne che sia efficace per tutti i pazienti. La gravità e la tipologia dell'acne possono variare notevolmente da persona a persona, quindi è necessario adottare un'approccio personalizzato nella scelta delle terapie. Tuttavia per la maggior parte dei pazienti affetti da acne è possibile individuare una terapia adeguata che miri a ridurre le lesioni e migliorare lo stato della pelle. Questa terapia può includere l'uso di prodotti topici come creme, gel o lozioni contenenti ingredienti come il perossido di benzoile, gli acidi esfolianti o i retinoidi[4]. Non esiste una vera e propria scala di valutazione dell'acne ma solitamente la patologia è suddivisa in tre sfere di gravità[3]:

- *Mild*;
- *Moderate*;
- *Severe*.

Un esempio che comprende immagini relative alle tre categorie di acne è riportata nella figura 2.1.

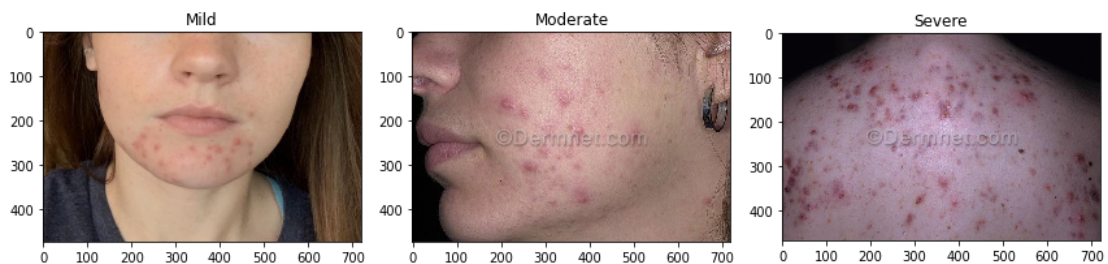


Figura 2.1: Le tre tipologie di acne : Mild, Moderate e Severe

2.1.2 Psoriasi

La psoriasi è una malattia infiammatoria cronica ed eterogenea, mediata dal sistema immunitario, che può interessare la pelle, le unghie e le articolazioni.[5] La psoriasi, secondo la Federazione Internazionale delle Associazioni Psoriasi (IFPA), colpisce circa 125 milioni di persone nel mondo, corrispondente a circa il 2-3% della popolazione globale. Questo evidenzia come questa malattia abbia una ampia diffusione e un ampio impatto a livello globale.[6] In un soggetto affetto da psoriasi il sistema immunitario inizia ad attaccare le cellule della pelle, interrompendo il loro normale ciclo di vita e sviluppo. Una cellula, in normali condizioni, si sviluppa in circa 28-30 giorni, invece, nel caso in cui il soggetto sia affetto da psoriasi, questo ciclo viene accelerato, portando allo sviluppo di cellule cutanee in eccesso sulla superficie della pelle in soli 7 giorni.[6] Questa condizione dermatologica causa la formazione di macchie dense, pruriginose e gonfie che si diffondono poi in diverse parti del corpo. In aggiunta alle già fastidiose manifestazioni cutanee, la psoriasi viene spesso associata ad altri disturbi correlati quali l'artrite infiammatoria, le malattie cardiovascolari e depressione acuta. L'aspetto visibile della malattia, spesso comporta stigma sociale, impattando significativamente sulla qualità della vita dei soggetti affetti.[7] La psoriasi si presenta in diverse forme, tra cui:

1. **Psoriasi a placche:** è la manifestazione più comune di psoriasi, nell'80% delle persone la malattia si presenta in questa forma.[8] Le placche psoriasiche si rivelano spesso di colore rosso e coperte da squame argentee, come è possibile notare nella figura 2.2; possono comparire in diverse parti del corpo, come nel cuoio capelluto, sulla parte bassa della schiena, sui gomiti, sulle ginocchia e sulle aree di flessione come ascelle e inguine.[8] A livello cellulare, si osserva un'inflammazione cronica che porta all'ispessimento dello strato superficiale della pelle (epidermide) e all'accumulo di cellule morte.[7]
2. **Psoriasi guttate:** è una forma di psoriasi caratterizzata dalla comparsa di piccole lesioni a forma di goccia sulla pelle, visibili nella figura 2.2. Questa forma di psoriasi è meno comune rispetto alla sopracitata a placche, si manifesta in particolare nei bambini, negli adolescenti e nei giovani adulti.[9] La guttata è spesso preceduta da un'infezione batterica o virale, come un'infezione delle vie respiratorie superiori o una tonsillite streptococcica. Le lesioni cutanee tipiche della psoriasi guttata appaiono piccole, rotonde o ovali e solitamente di colore rosa o rosso chiaro. Possono comparire su tutto il corpo incluso il tronco, le braccia, le gambe e il viso e sono generalmente asciutte ma possono essere accompagnate da prurito o sensazione di bruciore.

3. **Psoriasi inversa:** è una forma particolare di psoriasi che colpisce principalmente le zone in cui la pelle si piega, come l'inguine, le ascelle, l'area sotto il seno e le pieghe gluteali. Un esempio di questa variante è riportata in figura 2.2. A differenza delle altre forme di psoriasi, quest'ultima, presenta lesioni cutanee di colore rosso intenso che possono essere lisce, lucide e leggermente bagnate a causa dell'umidità presente nelle zone interessate. Questa manifestazione di psoriasi può essere scambiata erroneamente per un'infezione funginea o batterica a causa della sua presentazione caratteristica.[10] La psoriasi inversa può causare prurito, dolore e disagio nelle aree interessate.

4. **Psoriasi pustolosa:** è una forma rara e grave di psoriasi per la quale non esiste un trattamento standard ma spesso si segue quello utilizzato per la psoriasi a placche. Caratterizzata dalla formazione sulla pelle di pustole piene di pus spesso accompagnate da arrossamento, infiammazione e dolore. La psoriasi pustolosa può colpire diverse parti del corpo incluso il tronco, le mani, i piedi e le estremità. La psoriasi pustolosa è considerata una condizione autoimmune, in cui, il sistema immunitario attacca erroneamente le cellule della pelle. Tuttavia dagli studi anche recenti, la causa precisa della sua insorgenza non risulta ancora del tutto chiara.[11]

5. **La psoriasi eritrodermica:** è una forma estremamente rara e grave di psoriasi in cui la maggior parte della superficie corporea viene coinvolta da eritema diffuso e desquamazione intensa. Questa condizione è caratterizzata da un'infiammazione estesa della pelle che può coinvolgere l'intero corpo o la maggior parte di esso. Le persone affette da psoriasi eritrodermica possono sperimentare sintomi come prurito intenso, bruciore, dolore e sensibilità cutanea aumentata. La pelle colpita può apparire rossa, gonfia e calda al tatto. [12]




Figura 2.2: Esempio di psoriasi a Placche, Guttata e Inversa




Figura 2.3: Esempio di psoriasi Pustolosa e Eritrodermica

2.1.3 Dermatite Atopica

La dermatite atopica, nota anche come *eczema atopico*, è una malattia infiammatoria cronica della pelle caratterizzata da eruzioni cutanee pruriginose, secchezza cutanea, rossore e ispessimento della pelle. L'esordio della dermatite atopica nella maggior parte dei casi avviene nell'età infantile, tra i 2 e i 5 anni d'età anche se può persistere o manifestarsi anche in età adulta. Una stima sostiene questa malattia coinvolge tra il 15 e il 20% dei bambini e tra l'1 e il 3% degli adulti in tutto il mondo[13]. Frequentemente questa malattia può presentarsi anche accompagnata da asma e rinite allergica infatti circa il 30% dei bambini affetti da dermatite atopica sviluppano una forma di *asma*. Riconoscere e trattare precocemente la dermatite atopica può aiutare a prevenire gravi complicazioni associate alla condizione. Tra queste complicazioni rientrano disturbi del sonno causati dal prurito persistente, alterazioni cutanee croniche post-infiammatorie che possono causare arrossamenti, ispessimenti o discromie della pelle e la possibilità di sviluppare infezioni cutanee secondarie causate da batteri come *Staphylococcus*, *Streptococcus* e *Herpes* [14]. Le motivazioni dell'insorgenza della dermatite atopica non risultano ancora del tutto chiare. Si ritiene che una combinazione di fattori genetici, ambientali e immunologici giochi un ruolo nella sua insorgenza infatti le persone con una storia familiare di dermatite atopica, asma o allergie sono più suscettibili a sviluppare questa condizione. La dermatite atopica si presenta in quattro forme cliniche [14]:

1. **Forma acuta:** caratterizzata per la presenza di un'eruzione vescicolare con perdita di liquido e formazione di croste sulla pelle;
2. **Forma subacuta:** definita da papule e placche secche, squamose e eritematose;
3. **Forma cronica:** contraddistinta da un ispessimento e una ruvidità della pelle a causa dei frequenti graffi. Inoltre, è possibile osservare anche un'iperpigmentazione della pelle interessata. Questo fenomeno è caratterizzato da un aumento della produzione di melanina, il pigmento responsabile della colorazione della pelle che può portare a una colorazione più scura nelle aree affette dalla dermatite atopica;
4. **Pitiriasi:** forma particolare nota come *pitiriasi alba*, che si manifesta spesso nei bambini. Questa condizione si caratterizza per la presenza di placche ipopigmentate scarsamente delimitate e con una leggera desquamazione.

Nella figura 2.4 sono riportati un esempio di dermatite atopica in forma acuta e in forma subacuta, mentre nella figura 2.5 sono riportati un esempio della forma cronica e uno di pitiriasi alba.

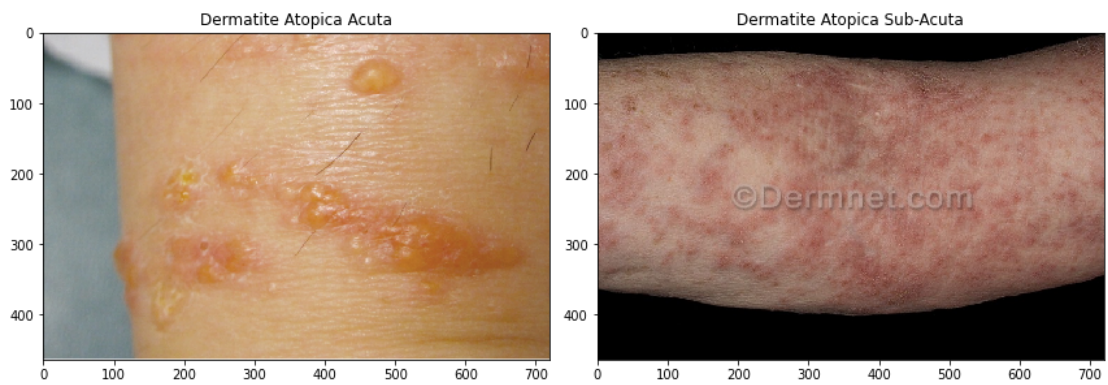


Figura 2.4: Esempio di Dermatite Atopica Acuta e Sub-Acuta




Figura 2.5: Esempio di Dermatite Atopica Cronica e Pitiriasi Alba

2.1.4 Sintomatologia comune

Nonostante la dermatite atopica, l'acne e la psoriasi siano malattie della pelle diverse spesso presentano alcune sintomatologie comuni. Tra i sintomi più frequenti si riscontrano prurito, infiammazione, arrossamento e la presenza di lesioni cutanee. È importante sottolineare che mentre l'acne e la psoriasi sono solitamente localizzate in specifiche aree del corpo come il viso, la schiena o le articolazioni, la dermatite atopica tende a interessare principalmente le pieghe della pelle come quelle del gomito e del ginocchio. Tuttavia, come già menzionato nel paragrafo precedente, la psoriasi inversa si manifesta anch'essa nelle zone interessate dalle pieghe cutanee. Questa caratteristica può rendere la diagnosi complessa soprattutto nei neonati e nei bambini piccoli poiché le manifestazioni possono presentarsi in modo molto simile[15]. La presenza di una morfologia intermedia tra queste malattie può quindi richiedere una valutazione approfondita da parte di un dermatologo o di un medico specialista per una diagnosi corretta e un trattamento adeguato. Quindi, sebbene la psoriasi sia di solito una diagnosi clinica può spesso ritenersi necessario eseguire una biopsia cutanea per confermarla e differenziarla dalla dermatite atopica. L'acne e la psoriasi possono presentarsi con lesioni cutanee come brufoli o pustole. Anche se le caratteristiche specifiche e la distribuzione delle lesioni possono differire, alcune forme soprattutto quelle meno acute possono essere facilmente confuse. Allo stesso modo, la dermatite atopica può manifestarsi con eruzioni cutanee pruriginose e arrossate che possono essere confuse con le altre due condizioni dermatologiche[16].

2.2 Metodi di supporto diagnostico computer based

Il monitoraggio di ogni paziente da parte di un dermatologo comporta costi elevati e la diagnosi accurata delle malattie cutanee richiede tempo. A tal proposito si rende necessario valutare l'utilizzo di un sistema di supporto diagnostico *computer based* per ottenere informazioni in maniera rapida ed economica[1]. I metodi *computer based* rappresentano una soluzione promettente per superare le limitazioni degli esami a occhio nudo; infatti, queste strategie consentono di esaminare in modo accurato e dettagliato le strutture sottosuperficiali delle lesioni cutanee fornendo una comprensione più oggettiva delle diverse forme di lesioni, dei loro aspetti visivi e delle loro caratteristiche distintive. Questo approccio offre, inoltre, vantaggi in termini di tempi di analisi ridotti e costi più contenuti, rendendolo un'opzione promettente per un sistema di supporto diagnostico efficace, conveniente e accessibile[17].

Negli ultimi tempi la ricerca in campo medico sull'utilizzo di algoritmi di *Machine Learning* (ML) e *Deep Learning* (DL) è incrementata notevolmente. I ricercatori si sono impegnati per sviluppare framework sempre più avanzati che possano essere utilizzati in varie applicazioni basate sull'*image processing*.

Le *reti neurali convoluzionali* (CNN) sono considerate il metodo all'avanguardia nell'analisi delle immagini mediche come quelle radiografiche (RX) e di risonanza magnetica (MRI). I modelli CNN nelle loro varianti come *ResNet*, *VGG-16*, *GoogleNet*, *AlexNet* o *MobileNet* hanno mostrato risultati significativi nel rilevamento, nel riconoscimento e nella classificazione delle patologie[18]. Tuttavia le architetture di deep learning come le CNN richiedono immense risorse computazionali e un'ampia quantità di dati immagine per addestrare il modello proposto[19]. A causa della mancanza di dati e risorse sufficienti, il campo dell'analisi delle immagini mediche per le malattie della pelle deve ancora esplorare appieno le sue potenzialità [18].

Un esempio di sistema automatico per il riconoscimento di immagini cliniche di malattie della pelle è il sistema proposto da Jainesh Rathod[20]. Nella fase di pre-elaborazione delle immagini sono stati utilizzati filtri per la rimozione del rumore e il miglioramento della qualità. Successivamente, al dataset *DermNet*[21], utilizzando un modello di CNN sono state estratte le features e classificate le immagini. I risultati sperimentali hanno riportato un'accuratezza del 70% nella rilevazione delle malattie della pelle.

Interessante è ancora lo studio proposto da Rifat Sadik[18] che propone un sistema composto da due modelli di CNN, in particolare con architetture di tipo *MobileNet* [22] e *Xception* [23], allenato su un dataset composto dall'unione di *DermNet* e *HAM10000* [24], utilizzando il *transfer learning* ovvero utilizzando modelli preallentati su **Imagnet**[25] per riuscire a ottenere più features significative.

Jessica Valasco, invece, propone una ricerca[26] che utilizza un modello di MobileNet, anch'esso allenato tramite metodo di *transfer learning*, per creare un sistema di classificazione delle malattie della pelle in un'applicazione Android. Sono state esplorate diverse tecniche di campionamento e pre-elaborazione dei dati per migliorare l'accuratezza del modello. I risultati hanno mostrato che l'uso di un dataset sbilanciato e l'oversampling del dataset hanno portato a un'accuratezza fino al 94,4%.

2.3 Applicazioni attualmente disponibili

Nel panorama attuale sono presenti diverse app per la classificazione delle malattie della pelle che offrono agli utenti la comodità di utilizzare strumenti di supporto diagnostico basati sull'intelligenza artificiale direttamente attraverso i propri dispositivi mobili. Tuttavia, è importante sottolineare che nonostante i progressi tecnologici, le app per la classificazione delle malattie della pelle non possono sostituire una diagnosi medica professionale. Sono strumenti complementari che forniscono informazioni e suggerimenti sebbene la consulenza di un dermatologo rimanga fondamentale per una diagnosi accurata e un trattamento adeguato delle condizioni cutanee. Di seguito sono riportati alcuni esempi di app attualmente disponibili agli utenti:

- **DermAssist:** è un'app innovativa sviluppata da Google Health che mira a rivoluzionare il modo in cui comprendiamo e identifichiamo le malattie della pelle. DermAssist utilizza algoritmi di Deep Learning e un vasto database di immagini legate alla pelle. Il processo dell'applicazione richiede tre foto della lesione cutanea, una serie di domande informative e in meno di un minuto l'utente può ottenere la classificazione delle immagini. Offre dunque un elenco completo di 288 condizioni cutanee, dei capelli e delle unghie unitamente a informazioni utili su ciascuna di esse. DermAssist è destinato a persone di età superiore ai 16 anni che cercano informazioni sulla loro pelle, ma non una diagnosi medica. Quest'applicazione mobile è stata classificata come dispositivo medico di classe 1 con marchio CE nell'Unione Europea mentre non è disponibile negli Stati Uniti poichè l'FDA(Food and Drug Administration) non l'ha incluso ai dispositivi medici ritenuti sicuri e affidabili;

- **SkinVision:** è un servizio medico che utilizza un'applicazione per smartphone per aiutare a prendersi cura della salute della pelle. L'applicazione combina l'intelligenza artificiale con l'esperienza dei dermatologi al fine di offrire una rilevazione accurata e tempestiva del cancro della cute, insieme a consigli personalizzati sulla salute della pelle. L'applicazione permette di creare la mappa corporea per tenere traccia regolarmente delle macchie e monitorarne i cambiamenti nel tempo. In base al tipo di pelle e al profilo di rischio, SkinVision fornisce consigli personalizzati sulla protezione dalla probabilità di sviluppare un melanoma e offre una valutazione, una consulenza e una cura personalizzate. Il servizio è classificato come dispositivo medico di classe 1 ed ha ottenuto il marchio CE ed è in grado di rilevare segni dei tipi più comuni di tumori cutanei con una sensibilità fino al 95% [skinvision];
- **FirstDerm:** è un'app che consente agli utenti di ottenere una valutazione preliminare delle proprie lesioni cutanee caricando foto e descrizioni dei sintomi. L'app utilizza l'intelligenza artificiale per analizzare le immagini e fornire una stima della gravità della condizione. I dati vengono quindi inviati a dermatologi esperti che esaminano le informazioni e forniscono una valutazione dettagliata entro 24 ore. Gli utenti possono ottenere consigli su come trattare la condizione o se necessitano di una visita medica più approfondita.

Capitolo 3

Raccolta e preparazione dei dati

Nel contesto di sviluppo di un modello di rete neurale per la classificazione, la raccolta dati e la costruzione di un dataset ben strutturato ricopre un ruolo fondamentale al fine di ottenere risultati significativi. In questo capitolo ci si concentrerà sulla raccolta e la pre-elaborazione dei dati prima di procedere all'allenamento del modello. La raccolta dati si è rivelata fin dall'inizio una fase critica del processo, proprio perché la qualità e la rappresentatività dei dati influiscono direttamente sull'efficacia del modello di rete neurale. A questo fine sono stati applicati criteri di inclusione ed esclusione dei dati per garantire che il dataset risultasse coerente all'obiettivo di ricerca e allo stesso rappresentativo delle tre malattie considerate e dei rispettivi sintomi. Durante la fase di raccolta dei dati, è stata riscontrata una limitazione significativa ossia la scarsa disponibilità di dati specifici. I principali dataset pubblici contenenti immagini di buona qualità relative alle malattie della pelle e con una buona qualità delle immagini si concentrano principalmente sulle lesioni cancerogene e includono immagini dermoscopiche, un esempio è l'HAM100000.[24][27] Le immagini dermoscopiche sono una rappresentazione ad alta risoluzione della pelle e vengono catturate utilizzando uno strumento chiamato *dermatoscopio o microscopio dermatologico*. Il loro studio consente una visualizzazione dettagliata delle lesioni cutanee. Le tecniche di acquisizione includono l'uso di ingrandimenti ottici, luce polarizzata o immersione in liquido e illuminazione a basso angolo di incidenza.[28] L'ingrandimento ottico permette di esaminare la lesione a livello microscopico rivelando dettagli che potrebbero non essere visibili a occhio nudo. La luce polarizzata, invece, viene utilizzata per ridurre i riflessi superficiali e migliorare il contrasto consentendo una migliore visualizzazione delle caratteristiche cutanee. L'immersione in liquido, come in olio o in acqua, aiuta a eliminare l'aria tra il dermatoscopio e la pelle riducendo le distorsioni ottiche

e migliorando la nitidezza delle immagini.[29] Attraverso l'analisi dermoscopia è possibile estrarre diverse informazioni sulla struttura e le caratteristiche delle lesioni cutanee. Queste informazioni includono:

- la valutazione dei bordi della lesione, possono essere regolari o irregolari;
- presenza di asimmetrie o irregolarità nella forma della lesione;
- presenza di aree blu o bianche, reti pigmentate e globuli.

L'analisi dermoscopia permette inoltre, di seguire la storia evolutiva della lesione permettendo di valutare i cambiamenti nella morfologia, nel colore e nella distribuzione dei caratteri dermoscopic.[28] Tuttavia, nel contesto dello sviluppo di un'applicazione che richiede l'utilizzo di immagini scattate da dispositivi mobili, non è possibile utilizzare direttamente le immagini dermoscopiche per cui questa tipologia di dataset risulta inutilizzabile. È importante considerare che le immagini scattate dai dispositivi mobili possono presentare alcune limitazioni rispetto alle immagini professionali o dermoscopiche. Queste limitazioni possono derivare dalla qualità dell'immagine, come la risoluzione della fotocamera, l'illuminazione ambientale, il posizionamento della lesione e le competenze fotografiche dell'utente. Per favorire il superamento delle limitazioni registrate sono state eseguite delle tecniche di elaborazione delle immagini, in particolare sono stati utilizzati gli algoritmi di color constancy per ridurre il rumore, ottimizzare il contrasto e normalizzare i colori, con lo scopo di ottenere risultati più accurati nella classificazione delle malattie.

3.1 Origine e composizione del Dataset

Punto di partenza per la composizione del dataset finale è sicuramente DermNet, dataset ampiamente utilizzato nella comunità scientifica per la ricerca e lo sviluppo di sistemi di intelligenza artificiale nel campo delle malattie della pelle[21][27]. DermNet è un dataset curato e compilato da professionisti medici esperti nel campo della dermatologia. Le immagini che lo compongono sono state acquisite da pazienti reali, le quali hanno fornito una rappresentazione autentica delle condizioni della pelle. Inoltre, una delle caratteristiche distintive e più incisive del dataset DermNet è la sua diversità, essa infatti copre una vasta gamma di etnie, gruppi di età e tipologie di pelle, consentendo di ottenere una rappresentazione più completa e inclusiva delle malattie cutanee. In aggiunta, Dermnet offre informazioni dettagliate per ogni immagine comprese la diagnosi associata e una descrizione delle caratteristiche rilevanti della lesione. Queste informazioni risultano preziose nel contesto della valutazione delle performance dei sistemi di classificazione. Le immagini fornite da DermNet includono le diverse tipologie di Acne, Psoriasi e Dermatite atopica permettendo di esaminare le tre malattie e fornire al modello un dataset maggiormente eterogeneo. Un esempio di immagine di Psoriasi Guttate proveniente dal dataset Dermnet è riportato nella figura 3.1.

AtlasDerm [30] è l'altro dataset pubblico utilizzato al fine di incrementare i dati. AtlasDerm è stato creato con l'obiettivo di fornire una collezione di immagini che coprono una vasta gamma di condizioni dermatologiche. Anch'esso è stato sviluppato da una comunità di esperti dermatologi e professionisti del settore, garantendo l'autenticità e la rilevanza clinica delle immagini presenti nel dataset. Come in DermNet, vengono fornite informazioni supplementari sulle condizioni cutanee associate a ciascuna immagine. Queste informazioni includono descrizioni testuali delle lesioni, sintomi, storia clinica e terapie raccomandate che possono essere utili alla comprensione delle caratteristiche e del contesto in cui si sviluppano queste malattie dermatologiche. Un esempio di immagine di Acne proveniente dal dataset Dermnet è riportato nella figura 3.2.

Il dataset finale è stato ottenuto selezionando attentamente le immagini andando a escludere quelle acquisite in contesti clinici. In questo modo, si è garantita una maggiore rappresentatività delle immagini scattate in ambienti reali come quelle ad esempio catturate dagli utenti attraverso dispositivi mobili. Dopo le opportune rifiniture il dataset risulta composto da 5015 immagini di cui:

- 2247 di **Acne**;
- 1510 di **Psoriasi**;
- 1257 di **Dermatite Atopica**.



Figura 3.1: Psoriasi Guttate provenienti da Dermnet



Figura 3.2: Acne proveniente da atlasDerm

3.2 Pre-elaborazione dei dati e Data Augmentation

Particolare attenzione è stata posta alla preparazione delle immagini del dataset circa l'addestramento del modello durante la fase di pre-elaborazione dei dati. Le immagini sono state caricate all'interno dell'ambiente di sviluppo Python, e successivamente è stata applicata una trasformazione utilizzando la funzione **resize** della libreria *Skimage*. Questa operazione ha consentito di ridimensionare le immagini portandole a una dimensione di input standard di 224x224x3. Il parametro **preserve range** è stato impostato a **True** in modo da mantenere il range di valore dei pixel originali dell'immagine e preservare tali valori per l'addestramento del modello. Per quanto riguarda il parametro **anti aliasing** che effettua un filtro Gaussiano per ridurre l'effetto di aliasing, il quale si verifica quando le alte frequenze dell'immagine vengono erroneamente riprodotte come frequenze più basse nell'immagine ridimensionata; è stato impostato come **False** poiché i valori dei pixel sono interi quindi è consigliato utilizzare il metodo di interpolazione **nearest neighbor** per ridurre il costo computazionale. Successivamente è stato applicato al dataset un processo di data augmentation utilizzando l'API di *Keras ImageDataGenerator*. È stato osservato in letteratura che l'utilizzo della data augmentation ha portato a un miglioramento significativo delle prestazioni rispetto ai modelli addestrati senza questa tecnica.[31] Attraverso la data augmentation, sono state applicate diverse trasformazioni e manipolazioni alle immagini del dataset con l'obiettivo di simulare variazioni realistiche che possono essere presenti nei dati di test, fornendo al modello una maggiore varietà di esempi da utilizzare durante l'addestramento. Queste trasformazioni includono:

- **Width shift range** e **Height shift range**: specificano l'intervallo di spostamento orizzontale e verticale delle immagini. Il valore è stato impostato a 0.1, l'immagine può essere traslata casualmente del 10% della sua larghezza o altezza;
- **Zoom range**: specifica l'intervallo di zoom delle immagini. Il valore è stato impostato a 0.1, l'immagine può essere ingrandita o rimpicciolita del 10% in modo casuale;
- **Horizontal flip** e **Vertical flip** determinano se effettuare o meno un'inversione orizzontale o verticale delle immagini. Queste trasformazioni sono utili alla gestione delle asimmetrie delle malattie della pelle per cui sono state impostate entrambe come **True**;
- **Fill mode**: specifica come riempire i pixel dell'immagine in caso di spostamenti o zoom che creano aree vuote. L'opzione che è stata selezionata è **nearest** ovvero, i pixel vuoti vengono riempiti con i valori dei pixel più vicini.

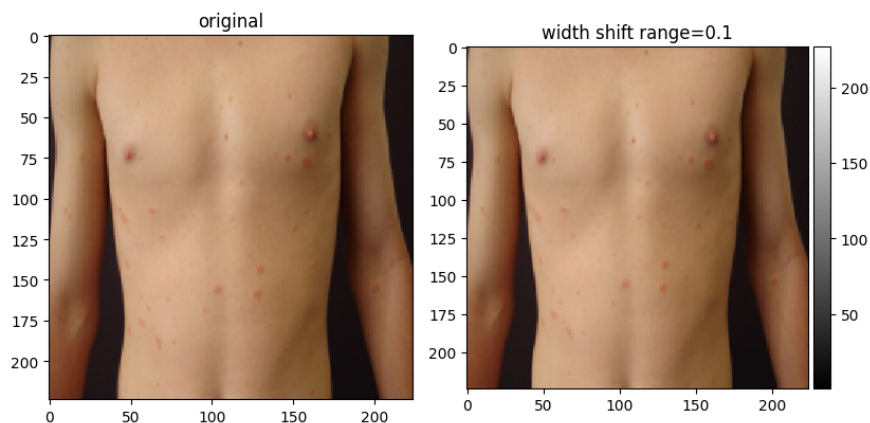


Figura 3.3: Immagine Originale e Immagine con width shift range di 0.1




Figura 3.4: Immagine con height shift range di 0.1 e flippata orizzontalmente




Figura 3.5: Immagine flippata verticalmente

3.3 Implementazione algoritmi di color constancy

Il principale obiettivo che il progetto si propone è quello di fornire agli utenti un'applicazione in grado di classificare accuratamente le immagini delle lesioni cutanee, indipendentemente dalla fotocamera utilizzata o dalle condizioni di illuminazione in cui le immagini sono state acquisite. Con l'utilizzo degli algoritmi di color constancy si mira a ridurre al minimo gli effetti negativi delle variazioni di illuminazione e a fornire una rappresentazione dei colori, il più possibile, coerente e standardizzata per l'intero dataset. Il concetto principale dietro gli algoritmi di color constancy risiede nella concezione che l'occhio umano ha la facoltà di adattarsi all'illuminazione ambientale e di percepire i colori degli oggetti in modo coerente indipendentemente dalle condizioni di luce. Gli algoritmi di color constancy non fanno altro che cercare di emulare questa capacità umana.[32] Uno degli approcci spesso utilizzati in questo tipo di algoritmi è quello della ricerca di punti di riferimento all'interno dell'immagine, essi rappresentano colori noti o neutri, come punti bianco o grigio nella scena e l'utilizzo di essi per correggere o calibrare il bilanciamento del colore dell'intera immagine. Tra i vari algoritmi di color constancy sono stati selezionati:

- **Gray world:** Proposto da G. Buchsbaum[33], si basa sull'assunzione che la media dei colori di una scena corrisponda sempre al colore grigio e che qualsiasi deviazione dal grigio sia causata esclusivamente dal colore specifico della fonte luminosa utilizzata;
- **Max RGB:** Noto anche come White-Patch [34], opera calcolando il valore massimo per ciascun canale RGB (rosso, verde e blu) all'interno dell'immagine di input. Successivamente, ogni canale viene scalato dividendo i valori dei pixel per il corrispondente valore massimo trovato nel rispettivo canale.

3.3.1 Gray World

L'implementazione del filtro Gray World è stata effettuata inizialmente in **Python**, utilizzando la libreria *Numpy*, e successivamente tradotta in **Dart** per essere integrata all'interno dell'applicazione, e prevede cinque passaggi:

1. Definizione della funzione che prevede l'input di un'immagine: array *NumPy*;
2. Calcolo della media dei valori dei tre canali RGB;
3. Calcolo del fattore di scala per ogni canale di colore dividendo la media del canale verde per la media del canale rosso e la media del canale verde per la media del canale blu. Questo assicura che la media del canale verde sia considerata come valore di riferimento;

4. Applicazione della correzione del colore moltiplicando i valori dei pixel di ciascun canale per il rispettivo fattore di scala. La funzione **clip** di *NumPy* ci assicura che i valori dei pixel risultanti siano compresi tra 0 e 255. Viene utilizzato il metodo **astype** per convertire i valori dei pixel in **uint8**;
5. Restituzione dell'immagine modificata come array *NumPy*.

È stato riportata nella listing 3.1, il codice Python relativo al filtro Gray World implementato e nelle figure 3.6 e 3.7 il confronto tra immagine originale e filtrata.

```
1 def gray_world(img):
2     # Calcola la media dei canali di colore
3     avg_r = np.mean(img[:, :, 0])
4     avg_g = np.mean(img[:, :, 1])
5     avg_b = np.mean(img[:, :, 2])
6
7     # Calcola il fattore di scala per ogni canale
8     scale_r = avg_g / avg_r
9     scale_g = 1.0
10    scale_b = avg_g / avg_b
11
12    # Applica la correzione del colore
13    img[:, :, 0] = np.clip(img[:, :, 0] * scale_r, 0, 255).astype(
14    np.uint8)
14    img[:, :, 1] = np.clip(img[:, :, 1] * scale_g, 0, 255).astype(
15    np.uint8)
15    img[:, :, 2] = np.clip(img[:, :, 2] * scale_b, 0, 255).astype(
16    np.uint8)
17    return img
```

Listing 3.1: Python script Gray World



Figura 3.6: Dermatite Atopica Originale



Figura 3.7: Dermatite Atopica filtrata con Gray World

3.3.2 Max RGB

L'implementazione del filtro Max RGB o White Patch è stata effettuata in **Python**, utilizzando la libreria *NumPy* in quattro passaggi:

1. Impostazione del parametro percentile, rappresenta il valore del percentile da considerare come massimo per ogni canale di colore. Il valore utilizzato è 100, che corrisponde al valore massimo possibile per ogni canale.;
2. Normalizzazione dell'immagine, la si divide per il valore massimo ottenuto per ogni canale RGB;
3. Creazione di una nuova immagine utilizzando la funzione **clip** per limitare i valori tra 0 e 1. Successivo scalamento dei valori dei pixel in un intervallo tra 0 e 255.
4. Restituzione dell'immagine modificata come array *NumPy*.

È stato riportata nella listing 3.2, il codice Python relativo al filtro Max RGB implementato nelle figure 3.8 e 3.9 il confronto tra immagine originale e filtrata.

```
1 def max_RGB(image, percentile=100):
2
3     # Calcola il valore massimo tra i canali RGB per ogni pixel
4     # dell'immagine
5     max_value = np.percentile(image, percentile, axis=(0, 1))
6
7     # Normalizza l'immagine dividendola per il valore massimo
8     # ottenuto per ogni canale RGB
9     normalized_image = image / max_value
10
11    # Limita i valori dell'immagine all'intervallo compreso tra 0
12    # e 1
13    clipped_image = np.clip(normalized_image, 0, 1)
14
15    # Scala i valori dell'immagine nel range 0-255
16    scaled_image = (clipped_image * 255).astype(np.uint8)
17
18    # Restituisce l'immagine scalata e convertita in formato uint8
19    return scaled_image
```

Listing 3.2: Python script Max RGB



Figura 3.8: Dermatite Atopica Originale



Figura 3.9: Dermatite Atopica filtrata con Max-RGB

3.4 Divisione dei dati in set di addestramento e Test Set

La separazione del dataset in set di addestramento e set di test riveste un'importanza fondamentale nel processo di sviluppo di un modello di rete neurale. L'obiettivo è di fornire al modello un training set vario e consistente in modo che possa generalizzare correttamente su nuovi dati. L'intero dataset, composto dall'unione dei dati raccolti da DermNet e atlansDerm, è stato inizialmente suddiviso in tre sottoinsiemi di dati:

1. **Training Set:** detto anche set di addestramento, rappresenta l'insieme dei dati utilizzati per l'apprendimento vero e proprio del modello ovvero quei dati utilizzati per ottimizzare i suoi parametri al fine di minimizzare la *funzione di loss* o di costo. La funzione di loss misura la discrepanza tra le previsioni del modello e i valori di output corretti. L'obiettivo è proprio quello di andare a minimizzare la funzione di loss, così da diminuire l'errore tra label reale e predetta. Di fondamentale importanza durante la creazione di un set di training è porre attenzione affinché ci sia un'alta varianza intraset. Essa comporta la presenza all'interno del set di una vasta gamma di esempi che rappresentano le varie sfumature, le differenze e le peculiarità delle immagini nel dominio specifico. Questo implica che il set di training comprenda casi di malattie della pelle con diverse manifestazioni, diverse localizzazioni o differenti livelli di gravità. L'inclusione di una varietà di immagini nel set di training è importante perché consente al modello di apprendere le caratteristiche comuni e le variazioni specifiche delle diverse patologie dermatologiche. Ciò aumenta la capacità del modello di generalizzare correttamente e di fare previsioni accurate su nuovi casi che non sono stati inclusi nel set di addestramento.
2. **Validation Set:** è una parte del dataset che viene utilizzata per valutare le prestazioni del modello durante il processo di addestramento per ottimizzare i suoi iperparametri. I dati contenuti in questo set non sono utilizzati direttamente dal modello durante la fase di apprendimento ma servono per valutare la capacità del modello di generalizzare su dati differenti e prevenire l'*overfitting*. Quest'ultimo si verifica quando l'errore relativo alla nostra curva di apprendimento è paragonabile allo zero ovvero tutti i dati che compongono il set di training o la maggior parte di essi, vengono correttamente classificati dal modello. Nulla di tutto ciò porterebbe a pensare che si tratti di un effetto indesiderato, tuttavia, la curva di apprendimento potrebbe nascondere del rumore. Quando si verifica l'*overfitting*, il modello memorizza i dettagli specifici dei dati di addestramento inclusi i rumori e le eccezioni, invece di imparare i pattern generali e le caratteristiche più rilevanti. Di conseguenza il modello può avere una performance eccezionale sui dati di addestramento ma risultare

meno accurato nel fare previsioni sui nuovi dati[35]. Ci sono diversi fattori che possono contribuire all'overfitting, tra cui:

- **Complessità del modello:** Modelli molto complessi con un numero elevato di parametri hanno una maggiore flessibilità nel modellare i dati di addestramento ma possono adattarsi eccessivamente a rumori o eccezioni presenti in quei dati compromettendo la capacità di generalizzazione su nuovi dati[35].
- **Set di addestramento troppo piccolo:** Se il set di addestramento è limitato in termini di dimensione o varietà, il modello potrebbe non essere in grado di apprendere in modo rappresentativo tutte le possibili variazioni e pattern presenti nei dati portando a una performance sub-ottimale sui nuovi dati.
- **Durata di addestramento eccessiva:** Un addestramento prolungato del modello può portare all'overfitting poiché il modello può specializzarsi sui dati di addestramento piuttosto che apprendere i pattern generali.

Per affrontare l'overfitting è possibile adottare diverse strategie tra cui l'uso di un validation set separato per monitorare le prestazioni del modello durante l'addestramento e evitare che si specializzi eccessivamente sui dati relativi al set di training.

3. **Test Set:** a differenza del set di addestramento e del validation set, esso rappresenta un insieme di dati completamente indipendente che non è utilizzato durante il processo di addestramento o di ottimizzazione dei parametri del modello. Il test set viene utilizzato per valutare le prestazioni del modello su nuovi dati consentendo di valutare le capacità di generalizzazione di quest'ultimo. È importante che sia il più possibile rappresentativo di tutti i casi che il modello potrebbe incontrare e con i quali potrebbe entrare in difficoltà.

L'approccio iniziale ha previsto la divisione del dataset, composto dalle immagini prese da DermNet e atlansDerm, nei tre set di addestramento elencati sopra rispettivamente con:

- 3409 immagini nel Training (il 68% del totale);
- 853 immagini nel Validation (il 17% del totale);
- 753 immagini nel Test (il 15% del totale).

Le prime prove di addestramento hanno subito rilevato che ricavare il set di test direttamente dal dataset di partenza risulta troppo increscioso sulle prestazioni del modello, in quanto la varianza all'interno del dataset è troppo alta rispetto alle

poche immagini a disposizione nel training.

La psoriasi e la dermatite atopica sono due condizioni dermatologiche caratterizzate da manifestazioni sintomatologiche molto diverse. Questa diversità comporta un'alta varianza all'interno di ciascuna delle due classi rendendo la disponibilità di un numero esiguo di campioni nel dataset di addestramento una limitazione significativa. Per ovviare a questa limitazione si è costituito di un dataset di Test con immagini provenienti da due atlanti dermatologici: *dermatoweb.net*[36] e *dermis.net*[37]. In entrambi gli atlanti sono disponibili ampie descrizioni delle patologie e dei trattamenti relativi a ogni immagine disponibile, il tutto validato da dermatologi esperti. Il dataset di test finale, composto dall'unione delle immagini ricavate dai due atlanti, risulta costituito da 302 elementi di cui:

- 85 di Acne;
- 115 di Psoriasi;
- 102 di Dermatite Atopica.

Nella figura 3.10 è riportata un immagine di acne ottenuta dall'atlande *dermis.net* mentre nella figura 3.11 è riportata un immagine di dermatite atopica presa dall'atlande *dermatoweb.net*.



Figura 3.10: Acne proveniente da Dermis.net



Figura 3.11: Dermatite Atopica proveniente da Dermatoweb.net

Capitolo 4

Implementazione, addestramento e valutazione delle prestazioni dei modelli

Di seguito verranno esaminati i dettagli del processo di implementazione e addestramento del modello di rete neurale utilizzato per la classificazione delle malattie cutanee. Saranno descritti i passaggi fondamentali come la scelta dell'architettura del modello e dei suoi iperparametri. Inoltre, sarà fornita una panoramica delle librerie e dei framework utilizzati per l'implementazione del modello.

In questo progetto si è scelto di utilizzare reti neurali convoluzionali essendo maggiormente impiegate nell'immagine recognition rispetto alle reti neurali completamente connesse (*fully connected*) per diverse ragioni[38]:

- **Minore quantità di parametri:** Le CNN utilizzano filtri convoluzionali che si spostano lungo l'immagine per individuare caratteristiche locali come linee, bordi o texture. Questi filtri catturano in modo efficiente informazioni locali riducendo la quantità di parametri da apprendere rispetto ad una rete fully connected.
- **Mantenimento della relazione spaziale tra i pixel:** Poiché le immagini sono composte da pixel che hanno una disposizione spaziale, la connettività locale delle CNN permette loro di catturare e sfruttare le informazioni spaziali come la posizione delle features nell'immagine rendendo possibile il riconoscimento accurato di patterns e strutture.

- **Capacità di apprendere features in gerarchie:** Le CNN sono in grado di apprendere gerarchie di features in modo progressivo. I primi strati della CNN imparano caratteristiche di basso livello come bordi e texture, mentre i livelli successivi combinano queste caratteristiche per riconoscere pattern più complessi e strutture più ad alto livello.

Per ovviare al problema della scarsa disponibilità di campioni di alta qualità è stata utilizzata la tecnica del *transfer learning*. Essa consiste nel trasferimento delle conoscenze apprese da un problema correlato a un nuovo problema consentendo di sfruttare le caratteristiche estratte dai dati precedenti. Nel contesto delle reti neurali convoluzionali (CNN) il transfer learning implica l'utilizzo di un modello pre-addestrato su un ampio set di dati. Questo modello ha già appreso una serie di features comuni a diverse immagini come bordi, texture e forme. Successivamente, il modello viene adattato al nuovo problema di classificazione attraverso un processo di *fine-tuning*. In questa fase si sostituisce l'ultimo strato del modello CNN esistente con un nuovo strato appositamente progettato per il problema specifico. La procedura standard prevede che si congeli uno o più strati convoluzionali precedenti impedendo che i loro pesi vengano aggiornati durante l'addestramento, mentre i livelli completamente connessi del modello vengono riaddestrati per apprendere le features relative al nuovo problema di classificazione[39]. Questa tecnica in sintesi offre numerosi vantaggi tra cui principalmente:

1. Maggiore efficienza nell'addestramento della rete;
2. Migliore generalizzazione su un set di dati meno numeroso;
3. Riduzione del rischio di overfitting.

Nel corso degli anni sono stati sviluppati diversi modelli di reti neurali convoluzionali per una vasta gamma di applicazioni nel campo della computer vision. Questi modelli sono diventati dei punti di riferimento per il riconoscimento di pattern e per l'analisi delle immagini. Sono stati addestrati su un'enorme quantità di immagini provenienti dal dataset ImageNet[25] composto da elementi con dimensione di 224x224 pixel. Alcuni di questi modelli, noti come modelli pre-addestrati, sono resi disponibili per l'uso pubblico. Essi sono in grado di classificare le immagini in diverse categorie di items: animali, strumenti domestici. I modelli pre-addestrati più noti includono *DenseNet*, *MobileNet*, *ResNet*, *Inception*, *VGGNet* e ognuno ha caratteristiche e prestazioni uniche. Questi modelli sono differenziati in base al numero di strati, alla mappatura delle caratteristiche, all'efficienza computazionale e alla complessità del modello[40].

4.1 Architettura della rete neurale

Al fine di ottenere il miglior modello possibile per la classificazione delle malattie cutanee fin'ora prese in esame ovvero Acne, Psoriasi e Dermatite Atopica sono state effettuate varie prove con diverse architetture di rete note per cercare di ottenere prestazioni ottimali. Tra queste, le architetture ResNet50, InceptionV3 e MobileNetV2 sono state selezionate per la loro efficacia comprovata in applicazioni di *image recognition* e *computer vision*.

4.1.1 ResNet 50

ResNet-50[41] è una variante dell'architettura del modello ResNet, si tratta di una rete neurale convoluzionale profonda composta da 50 blocchi residui. Ogni blocco residuo contiene più strati convoluzionali con normalizzazione del batch e funzioni di attivazione ReLU. L'aspetto unico di ResNet è l'utilizzo di connessioni di skip o shortcut che consentono alla rete di apprendere mappature residue. Queste connessioni di skip consentono alle informazioni di bypassare determinati strati affrontando il problema del gradiente che si annulla e agevolando l'addestramento di reti molto profonde[39].

ResNet-50 utilizza in particolare filtri 3x3 e 7x7 a diversi strati per catturare sia le caratteristiche locali che globali dell'immagine di input. Questa architettura è spesso utilizzata in applicazioni di image recognition in quanto i modelli riescono a raggiungere ottime prestazioni per questi tipi di tasks.

4.1.2 Inception V3

Il modello Inception[42] è stato proposto da Szegedy ed al. nel 2016 ed è caratterizzato da un'architettura profonda 48 layer. L'architettura Inception, permette ai suoi strati interni di selezionare la dimensione del filtro più adatta per l'apprendimento delle informazioni. Inoltre, è caratterizzato da layer con connessioni residue con lo scopo di velocizzare l'addestramento. L'Inception utilizza diverse dimensioni di filtro[39], tra cui:

- 64 filtri con kernel di convoluzione 1×1 (impiegati per la riduzione della dimensionalità);
- 128 filtri con kernel di convoluzione 3×3 ;
- 32 filtri con kernel di convoluzione 5×5 ;
- 32 filtri con kernel di convoluzione 3×3 per il max pooling.

4.1.3 MobileNet V2

MobileNet[22] è un modello basato su CNN ampiamente utilizzato per la classificazione delle immagini. L'architettura di MobileNet è progettata per richiedere meno risorse computazionali rispetto ai modelli CNN convenzionali rendendolo ideale per l'utilizzo su dispositivi mobili o computer con capacità computazionali limitate. Questa struttura semplificata incorpora un layer di convoluzione che è in grado di distinguere i dettagli rilevanti utilizzando due caratteristiche gestibili che bilanciano l'accuratezza dei parametri e la latenza in modo efficiente. Inoltre, MobileNet offre il vantaggio di ridurre la dimensione complessiva della rete rendendola più efficiente e leggera[43].

La struttura di MobileNet è stata progettata per avere sia livelli di astrazione in profondità che puntuali, sfruttando l'unità lineare rettificata standard (ReLU). Inoltre, viene aggiunto un parametro di moltiplicazione della risoluzione per ridurre la dimensionalità dell'immagine di input e delle rappresentazioni interne di ciascun layer. L'architettura MobileNet V2 riportata nella figura 4.1 è costituita da un layer residuale con stride 1 e un layer di riduzione delle dimensioni con stride 2 entrambi accompagnati dal componente di ReLU. Sia il layer residuale che il layer di riduzione delle dimensioni comprendono 3 sottolayer ciascuno:

- **Il primo layer:** è una convoluzione 1×1 con ReLU6 come funzione di attivazione;
- **Il secondo layer:** è la Convolution Depth-Wise che esegue un processo di filtraggio leggero sull'input;
- **Il terzo layer:** è una convoluzione 1×1 senza non-linearità. In questo layer viene utilizzato il componente ReLU6 nel dominio di output.

Il componente ReLU6 viene utilizzato per garantire la robustezza in situazioni di bassa precisione e migliorare la casualità del modello. Tutti i layer hanno la stessa quantità di canali di output all'interno della sequenza complessiva.

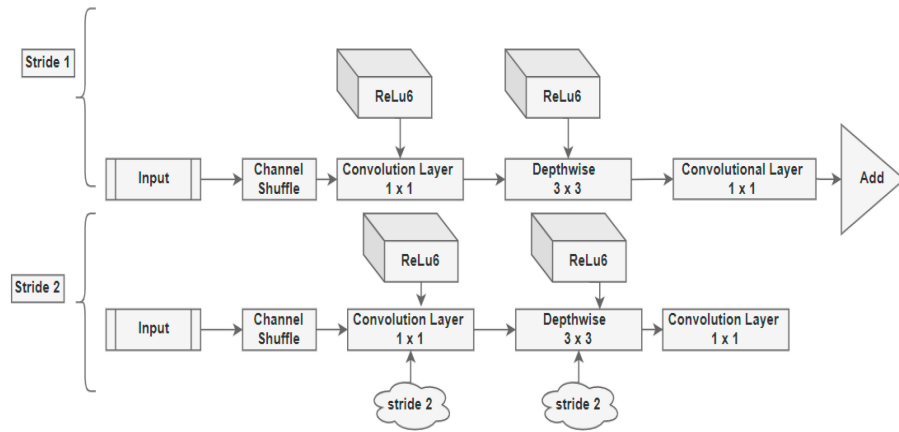


Figura 4.1: Architettura MobileNetV2[43]

4.2 Ambiente di sviluppo e librerie utilizzate

L'addestramento dei modelli pre-allenati nella fase di *fine-tuning* è stato effettuato sulla piattaforma **Google Colab**. Quest'ultima, è l'abbreviazione di *Google Collaboratory* che è un ambiente di sviluppo Python accessibile direttamente tramite browser e basata su cloud. Uno dei vantaggi principali di Colab è che offre un ambiente di sviluppo con accesso gratuito alle risorse di calcolo di Google comprese le unità di elaborazione grafica (GPU) e le unità di elaborazione tensoriale (TPU). Questo permette di sfruttare le potenze di calcolo per eseguire algoritmi di machine learning e deep learning in maniera più efficace. Un altro aspetto interessante di Colab è l'integrazione con altri servizi Google, come ad esempio Google Drive, permettendo all'utente di tener traccia dei file e dei notebook prodotti in cloud.

Per il fine-tuning del modello sono stati utilizzati i framework **TensorFlow** e **Keras**. TensorFlow è una libreria open-source per il machine learning sviluppata da Google diventata una delle librerie più popolari nel campo dell'intelligenza artificiale. Essa offre un'ampia gamma di strumenti e risorse per sviluppare e addestrare modelli di machine learning, compresi algoritmi di deep learning. Inoltre, tramite questa libreria è stato possibile accedere facilmente ai modelli pre-allenati pubblici delle maggiori architetture - citate nel paragrafo precedente - messi a disposizione da Google per l'accesso pubblico.

Keras, d'altra parte, ha semplificato il processo di creazione e configurazione del modello fornendo un'interfaccia intuitiva e user-friendly per la definizione degli strati e dei parametri del modello. L'uso congiunto di TensorFlow e Keras ha permesso di sfruttare al meglio le capacità di entrambi i framework, facilitando l'implementazione e l'addestramento dei modelli.

4.3 Configurazione di allenamento

I modelli pre-allenati ottenuti tramite TensorFlow dallo storage di Google presentano le caratteristiche riportate nella tabella 4.1. Come è possibile notare, la mobileNet è dotata di un numero significativamente inferiore di parametri di allenamento essendo un modello molto più leggero e ottimizzato per applicazioni di tipo mobile.

Tabella 4.1: Caratteristiche dei modelli pre-allenati

Modello	Numero di Parametri	Numero di Layers	Funzione di attivazione
ResNet 50	25,638,714	179	Softmax
Inception V3	23,853,786	315	Softmax
MobileNet V2	3,540,986	158	Softmax

Per garantire un addestramento ottimale e una valutazione accurata delle prestazioni del modello durante il processo di addestramento sono state effettuate varie prove preliminari sul dataset in modo da determinare la configurazione più performante dei vari parametri di addestramento specificabili. Ci si è particolarmente soffermati sulla scelta dell'algoritmo di ottimizzazione e della funzione di loss.

Durante l'addestramento del modello, l'algoritmo di ottimizzatore si occupa di aggiornare iterativamente i pesi e i bias delle connessioni neurali al fine di migliorare le prestazioni del modello. La funzione di loss, o funzione di costo, è una misura che quantifica quanto il modello predittivo si discosta dai valori di output corretti durante il processo di addestramento. Essa, infatti, rappresenta quantitativamente la discrepanza tra le previsioni del modello e le label reali dei dati forniti al modello. Gli algoritmi di ottimizzazione utilizzano tecniche matematiche per determinare la direzione e l'ampiezza degli aggiornamenti dei pesi e dei bias. L'obiettivo è trovare un punto di ottimo locale o globale in cui la funzione di perdita sia minima e le prestazioni del modello siano massime. Per quanto riguarda la scelta della configurazione di allenamento i parametri utilizzati sono rispettivamente:

- **Algoritmo di ottimizzazione:** è stato utilizzato **Adam**[44] con un **learning rate** (tasso di apprendimento) di 0.0001. Adam (Adaptive Moment Estimation) adatta dinamicamente il learning rate per ogni parametro in base alla stima del primo e secondo momento del gradiente. Il primo momento, chiamato media mobile, tiene traccia dell'andamento generale del gradiente e viene utilizzato per accelerare l'aggiornamento dei pesi. Mentre il secondo momento, chiamato varianza mobile o momento adattativo, tiene traccia della variazione del gradiente e viene utilizzato per adattare il tasso di apprendimento di ogni parametro;

- **Funzione di loss:** è stata utilizzata la **categorical cross entropy** che è molto comune in problemi di tipo multiclasse. Essa calcola l'entropia incrociata tra la distribuzione delle probabilità predette dal modello (p) e quella delle vere (y)[45]:

$$L(y_i - p_i) = - \sum_{i=1}^N y_i \cdot \ln(p_i)$$

L'indice i varia da 1 a N che rappresenta il numero delle classi e per ogni classe, si moltiplica la probabilità di appartenenza alla classe reale per il logaritmo della probabilità di appartenenza alla classe predetta. Il logaritmo viene applicato alla probabilità della classe predetta per sfavorire la discrepanza tra le due probabilità. Il segno meno, invece, serve per rendere positiva la funzione di loss.

- **Metriche:** durante l'addestramento del modello è stato scelto di monitorare la **categorical accuracy** relativa al dataset Validation. Viene monitorata la metrica per un dataset esterno al Training per cercare di limitare l'overfitting. L'accuratezza categorica è spesso utilizzata in problemi di classificazione di tipo multiclasse e misura la percentuale di predizioni corrette rispetto al numero totale di campioni per ogni classe.

$$\text{Categorical Accuracy} = \frac{\text{Numero delle predizioni corrette}}{\text{Numero totale dei campioni}}$$

- **Epoche di addestramento:** il numero massimo è stato impostato a 35 per evitare che il modello ricada nell'overfitting.

Inoltre sono stati definiti dei **callback** ovvero degli oggetti di Tensorflow e Keras che permettono di eseguire delle operazioni durante il processo di addestramento del modello in specifici momenti come ad esempio a inizio di ogni epoca. I callback impostati sono:

- **ModelCheckpoint:** viene utilizzato per salvare il miglior modello durante l'addestramento. Viene specificato il nome del file del modello da salvare, la metrica per determinare quando salvare il modello (in questo caso quando la categorical accuracy raggiunge il suo massimo), e il parametro `save_best_only=True` per salvare solo il modello con il miglior risultato sulla metrica specificata;

- **EarlyStopping:** viene utilizzato per interrompere l'addestramento prematuramente se una certa metrica, in questo caso la categorical accuracy del Validation, smette di migliorare. I parametri specificati includono la metrica per determinare quando interrompere l'addestramento, la *min_delta* che indica il miglioramento minimo richiesto per continuare l'addestramento e la *patience* che rappresenta il numero di epoche senza miglioramenti prima di interrompere l'addestramento;
- **ReduceLRonPlateau:** viene utilizzato per ridurre il learning rate quando una certa metrica smette di migliorare. Viene specificato la metrica per determinare quando ridurre il learning rate, la *patience* che rappresenta il numero di epoche senza miglioramenti prima di ridurre il learning rate e il *min_lr* che rappresenta il limite inferiore del learning rate sotto il quale non si può scendere.

4.4 Modelli in cascata

In un primo momento l'addestrando ha previsto un unico modello a tre classi ovvero Acne, Dermatite Atopica e Psoriasi. Sono state svolte 5 prove effettuando una divisione casuale del dataset diversa per ogni prova, ottenendo una categorical accuracy massima nella prova 5 pari all' 85.54% sul Validation. Nella tabella 4.2 sono riportati i risultati relativi alle altre prove. È importante sottolineare però che nonostante una categorical accuracy complessiva relativamente alta, in realtà, in tutte le prove vi è un grosso sbilanciamento nelle classi. È possibile riscontrarlo anche nella confusion matrix riportata in figura 4.2 dove si ottiene un'accuratezza solo del 65.65% sulla classe Dermatite Atopica mentre sulla classe acne si detiene un'accuratezza del 95.37%.

Per ovviare a questo problema sono stati implementati due modelli in cascata così da specializzare il secondo modello nella scelta tra le classi dove l'accuratezza risulta inferiore. Il primo modello è stato allenato su due classi: Acne e Not Acne e in quest'ultima sono state inserite le immagini relative alle malattie Psoriasi e Dermatite Atopica.

Il secondo modello è stato allenato con un dataset ridotto, composto esclusivamente dalle immagini relative alla Psoriasi e alla Dermatite Atopica e quindi addestrato nel riconoscere esclusivamente queste due classi. Inoltre, come pesi di partenza sono stati utilizzati quelli relativi al miglior modello Acne/NotAcne precedentemente addestrato.




Figura 4.2: Confusion Matrix relativa alla prova 5 sul Validation

Tabella 4.2: Categorical Accuracy relativa al Validation nelle 5 prove di divisione

	Prova 1	Prova 2	Prova 3	Prova 4	Prova 5
Categorical Accuracy	83,05%	84,67%	82,57%	81,89%	85,54%

4.4.1 Implementazione algoritmo di predizione

Risulta evidente fin dalle prime prove di allenamento che le prestazioni del modello Acne/Not Acne si dimostrino superiori a quelle del secondo modello. A tal proposito e considerando che le prestazioni del primo modello fin dalle prime prove sono state sempre superiori al 95%, la pypeline per la classificazione finale dell'immagine è il seguente:

1. L'immagine viene classificata dal primo modello, nel caso in cui la classe identificata è Acne il processo si ferma, altrimenti prosegue;
2. L'immagine Not Acne viene classificata dal secondo modello che ne verifica l'appartenenza alla classe Psoriasi o Dermatite Atopica;
3. Nell'eventualità che la probabilità di appartenenza a una delle due classi sia inferiore al 65% vengono prodotte tre immagini trasformate ovvero:
 - Immagine originale con Flip Verticale;
 - Immagine originale ruotata di un valore casuale compreso tra 0° e 15°;
 - Immagine originale zoomata sull'asse delle x di una percentuale casuale compresa tra 0 e 50%.
4. Le immagini trasformate, di cui si riporta un esempio nella figura 4.3, vengono classificate dal secondo modello e tramite *majority voting* viene determinata la classificazione finale dell'immagine.

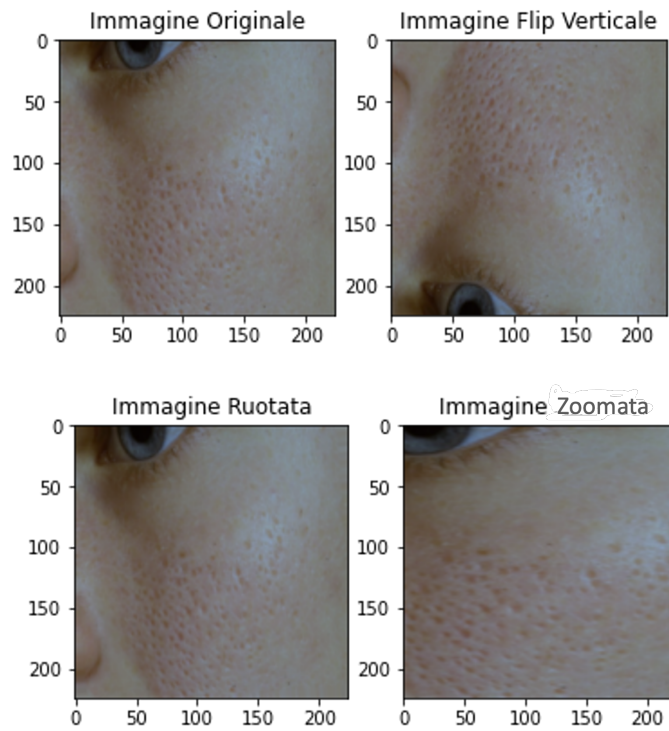


Figura 4.3: Immagine originale con le sue tre trasformazioni

4.5 Valutazione delle prestazioni

Durante la fase di training del modello sono state effettuate numerose prove di addestramento; dapprima, soffermandosi sulla bontà del pre-processing di conseguenza andando a valutare se migliorasse o meno le prestazioni del modello allenato con le immagini originali e successivamente, concentrandosi sulla scelta dell'architettura di rete che meglio performasse sullo specifico problema di classificazione.

4.5.1 Immagini originali vs Immagini Filtrate

Partendo dal presupposto di voler addestrare un modello che debba essere inserito all'interno di un applicazione mobile, si è scelto di cominciare a testare le immagini originali e confrontarle con quelle filtrate, utilizzando un modello pre-allenato dell'architettura MobileNet specifica per questo scopo.

Le immagini originali sono state portate a una dimensione di 224 x 224 x 3 essendo questo l'input standard per l'architettura di rete MobileNet. Sono state messe in atto varie prove. I modelli migliori hanno raggiunto una categorical accuracy del 97.50% per quanto riguarda il modello Acne/Not Acne; e una del 75.19% per il modello Psoriasi/Dermatite Atopica. Applicando l'algoritmo di predizione descritto nel paragrafo precedente, complessivamente, si ottiene una categorical accuracy dell'84.45%. Si notino nelle figure 4.4, 4.5 e 4.6 rispettivamente: la confusion matrix relativa al primo modello, al secondo e al risultato complessivo sul Validation.

Il modello Acne/NotAcne allenato con immagini filtrate con **Max RGB**, di cui è stata riportata l'implementazione nel paragrafo 3.3.2, ha ottenuto prestazioni complessivamente inferiori rispetto a quello allenato con le immagini originali. L'assunto implica che il pre-processing non solo non è efficace, ma risulta persino dannoso in termini di perdita di informazioni nel dataset. Per quanto concerne il secondo modello, si registra un aumento delle prestazioni seppur solo di qualche punto percentuale. Complessivamente si registra che la categorical accuracy non va oltre l'83.05%. Nelle figure 4.7, 4.8, 4.9 vengono riportate rispettivamente la confusion matrix relativa al primo modello, al secondo e al risultato complessivo sul Validation.

Relativamente alle immagini filtrate con il **Gray-World** invece, i risultati sono differenti. Il modello Acne/NotAcne ha delle prestazioni simili a quello allenato con le immagini originali, ottenendo una categorical accuracy del 97.21%. Per il modello Psoriasi/DermatiteAtopica, invece, si denota un incremento significativo nelle prestazioni, raggiungendo l'81.95% di categorical accuracy. Applicando l'algoritmo di predizione descritto nel capitolo precedente, complessivamente, si ottiene l'88.04%. Questo dato rappresenta un netto miglioramento delle prestazioni che sottolinea la necessità del filtraggio delle immagini. Nelle figure 4.10, 4.11 e 4.12 si vedano rispettivamente: la confusion matrix relativa al primo modello, al secondo

e al risultato complessivo sul Validation.

Nella tabella 4.3 è riportato un confronto sulle prestazioni dei modelli sulla base delle metriche utilizzate per valutarli, è stata presa in esame la classe Psoriasi, classe dove tutti i modelli hanno prestazioni inferiori.

Tabella 4.3: Confronto sulla classe Psoriasi sulla base della Precision, Recall e F1-Score

	Recall	Precision	F1-score
Originali	65,85%	84,24%	73,92%
Max-RGB	69,37%	87,56%	77,41%
Gray-World	78,17%	86,72%	82,22%




Figura 4.4: Confusion Matrix immagini originali Acne




Figura 4.5: Confusion Matrix immagini originali Psoriasi/Dermatite Atopica




Figura 4.6: Confusion Matrix complessiva sulle immagini originali




Figura 4.7: Confusion Matrix immagini Max-RGB Acne




Figura 4.8: Confusion Matrix immagini Max-RGB Psoriasi/Dermatite Atopica




Figura 4.9: Confusion Matrix complessiva immagini Max-RGB




Figura 4.10: Confusion Matrix immagini Gray World Acne

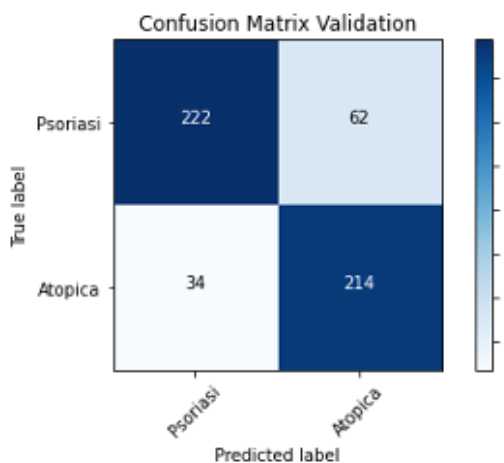


Figura 4.11: Confusion Matrix immagini Gray-World Psoriasi/Dermatite Atopica




Figura 4.12: Confusion Matrix complessiva immagini Gray World

4.5.2 Valutazione delle prestazioni sulle diverse architetture di rete

L'architettura MobileNet è specifica per applicazioni di tipo mobile, tuttavia, si è pensato di effettuare delle prove per garantire che le prestazioni del modello fossero le migliori ottenibili.

La prima prova è stata condotta utilizzando un modello pre-allenato di architettura **ResNet50** unitamente alle immagini filtrate con Gray-World e si è ottenuta un'accuratezza complessiva sui due modelli dell'85.84%. Nella figura 4.13 è riportata la confusion matrix relativa all'architettura ResNet50.

La seconda prova invece, è stata effettuata utilizzando un modello pre-allenato di architettura **InceptionV3** con le immagini filtrate con Gray-World. In questo specifico caso, le immagini sono state trasformate ad una dimensione di 299x299x3; misura standard per questo tipo di architettura. Si è ottenuta, a seguito dell'applicazione dell'algoritmo di predizione, un'accuratezza complessiva sui due modelli dell'81.16%. Nella figura 4.14 è riportata la confusion matrix relativa all'architettura InceptionV3.

Il modello migliore risulta in ogni caso essere quello addestrato a partire dal modello pre-allenato di MobileNetV2.

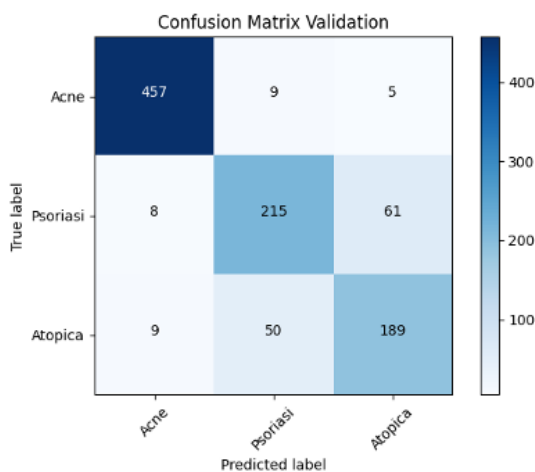


Figura 4.13: Confusion Matrix complessiva relativa all'architettura di rete ResNet50




Figura 4.14: Confusion Matrix complessiva relativa all'architettura di rete InceptionV3

4.5.3 Valutazione delle prestazioni del miglior modello sul Dataset di Test

Stabilita la miglior combinazione dei due modelli, ovvero quella con il quale si è ottenuto un F1-score sulla psoriasi di 82.22% e una categorical accuracy relativa alle tre classi di 88.04% sul Validation; si è andati a condurre il test del modello su un Dataset esterno. Al Test Set composto da immagini provenienti da due atlanti dermatologici *dermatoweb.net*[36] e *dermis.net*[37] descritti nel capitolo 3, è stato applicato lo stesso pre-processing utilizzato per le immagini con le quali è stata addestrata la miglior combinazione di modelli ovvero quello che comprende l'utilizzo del filtro di *color constancy* Gray-World. La categorical accuracy ottenuta è del 80.13%, in figura 4.15 si noti la confusion matrix relativa al dataset di Test.




Figura 4.15: Confusion Matrix complessiva sul Test

Capitolo 5

Progettazione e sviluppo di ADP Skin-Assistant

Il capitolo si propone di descrivere il processo di progettazione e implementazione dell'app mobile **ADP Skin-Assistant**; concentrandosi in particolare sugli elementi critici del processo quali, la scelta della piattaforma, l'interfaccia utente e l'integrazione dei modelli precedentemente addestrati.

5.1 Flutter

Per la fase di implementazione dell'app mobile è stato utilizzato **Flutter**. Flutter è un *framework open-source* sviluppato da Google che consente di creare app native per diverse piattaforme utilizzando un unico codice base. È stata preferita questa ad altre piattaforme perchè presenta numerose caratteristiche univoche che la rendono maggiormente adatta allo scopo, tra cui:

1. **Cross-platform**: è possibile scrivere un'unica base di codice e distribuire l'app su diverse piattaforme quali, Android, IOS, web e desktop. Questo consente di ridurre i tempi di sviluppo e di raggiungere un'ampia base di utenti senza dover riscrivere il codice nei diversi linguaggi necessari per la build sulle diverse piattaforme;
2. **Performance elevate**: utilizza il motore di rendering personalizzato **Skia**. Questa è una libreria di grafica 2D sviluppata da Google che fornisce funzionalità avanzate per il disegno, il rendering e la manipolazione di grafica vettoriale e bitmap. Inoltre, Flutter utilizza la compilazione *ahead-of-time* (AOT) che permette una conversione da linguaggio ad alto livello a linguaggio macchina prima dell'esecuzione dell'applicazione sul dispositivo. Questo fa sì che le prestazioni migliorino;

3. **Hot Reload:** questo meccanismo consente di visualizzare istantaneamente le modifiche apportate al codice nell'app in esecuzione, consentendo di poter sperimentare le modifiche in tempo reale senza dover eseguire nuovamente la built sull'emulatore;
4. **Ampia gamma di widget:** offre una vasta libreria di widget modificabili. Infatti, è possibile crearne di personalizzati e combinare elementi per costruire l'interfaccia desiderata;
5. **Linguaggio Dart:** il linguaggio di programmazione utilizzato è Dart che è facile da imparare e ha una sintassi simile a Java e JavaScript. Questo linguaggio offre una gestione efficiente della memoria e un'ottima scalabilità. Inoltre Dart, è un linguaggio moderno e flessibile che offre una sintassi chiara e facile da leggere rendendo lo sviluppo dell'app più performante.

Tuttavia, ci sono anche dei lati negativi nell'utilizzo di Flutter:

1. **Dimensione dell'app:** nonostante gli sviluppatori Flutter stanno cercando di risolvere questa limitazione con aggiornamenti e ottimizzazioni, le app sviluppate con questo framework solitamente risultano leggermente più grandi delle altre app native a causa dell'inclusione del motore di rendering;
2. **Community più giovane:** la community di Flutter è in crescita e all'attivo ma è ancora giovane rispetto ad altre comunità di sviluppatori. Questo comporta un numero inferiore di risorse e librerie rispetto ad altre tecnologie più consolidate. Si è riscontrata una difficoltà iniziale nel reperire i pacchetti relativi a Tensorflow che implementassero delle versioni compatibili con gli altri pacchetti necessari al funzionamento dell'app.

Nonostante ci siano alcune limitazioni nell'utilizzo di Flutter è stato comunque scelto di utilizzarlo nell'implementazione dell'applicazione utilizzando questo framework poichè è risultato il più efficace e ottimizzato per progetto in esame.

5.2 Requisiti dell'app

L'obiettivo è quello di creare un'applicazione semplice e accessibile con un'interfaccia user-friendly che permetta all'utente di approcciarsi in maniera efficace all'app. L'utente target non deve aspettarsi una diagnosi poichè non è quello che offre APD Skin-Assistant ma piuttosto un supporto informativo sulla propria lesione cutanea. L'applicazione non necessita dell'accesso alla rete internet, infatti può essere utilizzata offline gestendo tutti i dati in locale. I modelli precedentemente addestrati sono caricati in memoria e anch'essi non necessitano dell'accesso ad internet per il funzionamento.

L'applicazione prevede due modalità di acquisizione dell'immagine; l'utente può decidere se scattare la fotografia in tempo reale tramite l'accesso diretto alla fotocamera o scegliere una delle foto precedentemente scattate dalla galleria.

Il risultato della classificazione è riportato fornendo tre aree di probabilità di appartenenza alla classe Acne, Psoriasi o Dermatite Atopica che sono:

- Alta probabilità;
- Media probabilità;
- Bassa probabilità.

Le tre aree sono state implementate per indirizzare l'utente nella lettura del risultato consigliando sempre di vedere un dermatologo che possa confermare il sospetto di diagnosi anche in caso di classificazione con alta probabilità di appartenenza a una delle tre classi.

Risultato dell'utilizzo di **Flutter** è il supporto di diversi sistemi operativi in particolare Android e IOS. Attualmente, l'applicazione è stata sviluppata e testata tramite il supporto di un emulatore Android, nello specifico del dispositivo Pixel 3A. L'applicazione è supportata su dispositivi Android con una versione del sistema operativo uguale o superiore alla versione API 21 (Android 5.0 e successive). Qualsiasi dispositivo con una versione del sistema operativo Android inferiore alla versione API 21 non sarà in grado di installare o eseguire l'applicazione.

5.2.1 Interfaccia utente

Le caratteristiche dell'interfaccia utente (UI) sono gli elementi e gli aspetti che definiscono come gli utenti interagiscono con un'applicazione o un sito web. Una buona UI è essenziale per fornire un'esperienza utente piacevole e vantaggiosa. È stato dimostrato che un'interfaccia utente intuitiva influenza di molto l'utilizzo dell'applicazione da parte dell'utente[46].

La scelta cromatica non è avvenuta in modo casuale poichè dalla ricerca è emersa l'importanza della scelta dei colori nel design dei siti web / applicazioni mobile

e il loro potenziale impatto sulla percezione di fiducia degli utenti. Quando lo stesso sito web viene presentato con diverse scale cromatiche gli utenti tendono a percepire livelli di affidabilità differenti[47]. Tra le palette di colori testate, quelle di colore blu sono state percepite come le più affidabili [47]. A tal proposito si è scelto di utilizzare come colore principale proprio il blu; utilizzando varie sfumature per differenziare. Un esempio sono le tre schermate iniziali introduttive. La proposta di partenza è un blu più acceso per la prima schermata per poi scendere di gradazione fino ad arrivare alla colorazione utilizzata per lo sfondo delle altre schermate. Inoltre, si è scelto di utilizzare lo stesso grado di blu preso dal logo per i bottoni presenti nell'interfaccia così da favorire la continuità visiva.

Inizialmente, come citato nel paragrafo precedente, vengono visualizzate tre interfacce introduttive riportate rispettivamente in figura 5.1, 5.2, 5.3. Tra le schermate si può navigare utilizzando il classico swipe a destra/sinistra o i bottoni posizionati sul fondo delle pagine, con cui se si preferisce, si può anche saltare questa fase iniziale e passare alla schermata successiva. Le tre interfacce introduttive sono state impostate affinché vengano visualizzate esclusivamente al primo avvio dell'app. Infatti, dopo il primo caricamento dell'applicazione, viene tenuta traccia così da evitare che vengano mostrate al successivo avvio di quest'ultima. Nella prima schermata viene spiegato l'obiettivo di ADP SkinAssistant, nella seconda è riportata una breve spiegazione del funzionamento dell'app mentre nella terza e ultima schermata viene ricordato all'utente di rivolgersi a un dermatologo esperto per ricevere una vera e propria diagnosi e il suo relativo trattamento.

Terminata questa fase introduttiva, si passa alla schermata di avvio o *splash screen*(figura 5.4) dove viene visualizzato il logo e il nome dell'applicazione. Dopo un breve caricamento si arriva al nucleo dell'applicazione ovvero la homepage (figura 5.5).

La schermata sopracitata è il fulcro dell'intera applicazione difatti è qui che l'utente può caricare la propria immagine per la classificazione. L'utente può scegliere di cliccare sul bottone "**Apri fotocamera**" se preferisce scattare la fotografia della lesione cutanea in tempo reale o su "**Scegli una foto**" se invece vuole scegliere una foto archiviata nella galleria.

Una volta terminata la classificazione da parte dei modelli viene mostrata a schermo l'immagine scattata o selezionata dall'utente accompagnata dalla classificazione risultante in una delle tre fasce di probabilità di appartenenza. Nella figura 5.6 è mostrato un esempio di classificazione di un'immagine di una lesione acneica. Si è scelto di mantenere visibili i due bottoni anche a seguito della classificazione per permettere all'utente di procedere facilmente a una nuova classificazione se necessario.



Figura 5.1: Schermata introduttiva 1 di ADP SkinAssistant



Figura 5.2: Schermata introduttiva 2 di ADP SkinAssistant



Figura 5.3: Schermata introduttiva 3 di ADP SkinAssistant



Figura 5.4: Schermata di avvio di ADP SkinAssistant



Figura 5.5: Schermata home di ADP SkinAssistant



Figura 5.6: Schermata home di ADP SkinAssistant post classificazione

5.3 Architettura dell'app

Il framework **Flutter**, utilizzato per la creazione dell'app, presenta una struttura caratterizzata da pacchetti di terze parti da cui il progetto dipende che vanno dichiarate all'interno di un file di configurazione chiamato *pubspec.yaml*. Questi pacchetti possono essere librerie, plugin o altri moduli creati da sviluppatori della comunità Flutter in modo che quando avviene la compilazione vengono automaticamente scaricate e incluse nel progetto.

APD SkinAssistant dipende dai seguenti pacchetti esterni:

1. **Easy splash screen** versione 1.0.4, utilizzato per la creazione della schermata di caricamento iniziale dell'applicazione(*splash screen*);
2. **Image** versione 3.2.2, permette di caricare, leggere e manipolare le immagini in vari formati;
3. **Image picker** versione 0.8.7, fornisce le funzioni necessarie ad accedere alla fotocamera e selezionare le immagini dalla galleria del dispositivo;
4. **Smooth page indicator** versione 1.0.0, con il quale sono state realizzate le animazioni di scorrimento tra le tre schermate introduttive;
5. **Shared preferences** versione 2.2.0, utilizzato per determinare se l'applicazione è o meno stata avviata in precedenza;
6. **Tflite flutter plus** e **Tflite flutter helper plus** rispettivamente nelle versioni 0.0.1 e 0.02, forniscono le funzioni necessarie alla gestione dei modelli in formato Tensorflow lite. Inoltre, forniscono tutte le classi per la gestione dei dati di input e output di quest'ultimi.

Prima di procedere all'integrazione dei modelli Tensorflow precedentemente addestrati all'interno dell'applicazione si è proceduto alla conversione di essi in formato **TensorFlow Lite**. Questa trasformazione è una pratica comune per eseguire modelli di *deep learning* su dispositivi come smartphone, dispositivi IoT o dispositivi edge. I modelli TensorFlow Lite sono ottimizzati per essere più piccoli e leggeri rispetto a quelli TensorFlow standard consentendo di essere eseguiti su strumenti con capacità di memoria e potenza di calcolo ridotte.

All'avvio della schermata di Homepage vengono inizializzate due istanze della classe *Classifier* una per il modello Acne/Not Acne e la seconda per il modello Psoriasi/-Dermatite Atopica. Nella classe *Classifier* vengono a sua volta definite un'istanza della classe *ClassifierCategory* che contiene i metodi necessari a formattare l'output del modello nel formato desiderato e un'istanza della classe *ClassifierModel* i quali attributi contengono:

- Il modello (*Interpreter*);
- Le dimensioni di input e output dei tensori richiesti dal modello;
- Il tipo dei dati di input e output richiesti dal modello.

Inoltre, nella classe *Classifier* vengono definiti i metodi necessari all'intero processo di classificazione dell'immagine come:

- **__loadLabels** che permette la lettura da file delle label dello specifico modello;
- **__loadModels** con il quale si carica da file in locale il modello in formato TensorflowLite;
- **__preProcessInput** dove viene eseguito tutto il processo di pre-processing all'immagine acquisita come il ridimensionamento alle dimensioni di input richieste dal modello. Inoltre, avviene il richiamo del metodo **Gray-World** che esegue il filtraggio dell'immagine con il metodo di color constancy descritto nel paragrafo 3.3.1;
- **__predict** dove avviene la vera e propria esecuzione del modello e classificazione dell'immagine;
- **__postProcessOutput** nel quale viene formattato l'output del modello nel formato voluto, ovvero con la classe e la relativa probabilità di appartenenza.

Una volta ottenuta la label dell'immagine viene verificato lo score e eventualmente eseguito l'algoritmo di classificazione descritto nel paragrafo 4.4.1 prima che il risultato venga riportato a schermo.

Capitolo 6

Risultati e conclusioni

6.1 Prestazioni e limitazioni dell'app e del modello

Per effettuare una valutazione concreta delle performance del modello si è scelto di confrontarle con le prestazioni di dermatologi esperti. Si è fatto riferimento a uno studio [48] effettuato dal dipartimento di dermatologia del Peking Union Medical College Hospital scegliendo di concentrarsi sul secondo modello di CNN sviluppato; vale a dire un modello a due classi utilizzato per distinguere la psoriasi dalle altre malattie che si presentano con sintomatologie simili. Sono stati riuniti 164 dermatologi esperti ai quali è stato chiesto di classificare 60 immagini dermoscopiche precedentemente classificate dal modello; gli è stata fornita anche l'immagine clinica relativa. Questo poiché solitamente, la diagnosi in una visita dermatologica avviene sulla base di entrambe. Nella figura 6.1 si mostrano le performance dei modelli allenati nello studio sopracitato mentre nella tabella 6.1 sono riportate le metriche calcolate sul dataset di Test.

Le performance dei dermatologi sul riconoscimento della psoriasi si aggirano su una media di recall (sensitivity) del 87.20% con un limite inferiore del 65% e un limite superiore del 96,80%. Il modello allenato con filtro **Gray-World** implementato in APD SKinAssistant arriva ad una recall sulla classe psoriasi del 77,39% sul Test quindi ampiamente nel range dei dermatologi ma con performance ancora non pienamente soddisfacenti. I principali problemi di classificazione intercorrono quando le malattie cutanee presentano sintomi estremamente simili.

Tabella 6.1: Metriche relative al dataset di Test

	Acne	Psoriasi	Dermatite Atopica
Precision	89,02%	79,46%	78,43%
Recall	85,88%	77,39%	74,07%

Disease category	Dermatologists	CNN	P value
Multi-class model			
Basal cell carcinoma			
Sensitivity (95% CI)	0.770 (0.415–0.952)	0.800 (0.442–0.965)	–
Specificity (95% CI)	0.962 (0.868–0.992)	1.000 (0.925–1.000)	–
Kappa coefficient (95% CI)*	0.732 (0.500–0.964)	0.873 (0.700–1.000)	0.459
Melanocytic nevus			
Sensitivity (95% CI)	0.807 (0.565–0.938)	0.800 (0.557–0.934)	–
Specificity (95% CI)	0.897 (0.770–0.961)	0.840 (0.703–0.924)	–
Kappa coefficient*	0.690 (0.503–0.877)	0.604 (0.404–0.804)	0.537
Seborrheic keratosis			
Sensitivity (95% CI)	0.624 (0.386–0.818)	0.850 (0.611–0.960)	–
Specificity (95% CI)	0.976 (0.874–0.998)	0.940 (0.825–0.984)	–
Kappa coefficient (95% CI)*	0.662 (0.461–0.864)	0.790 (0.630–0.950)	0.331
Others			
Sensitivity (95% CI)	0.939 (0.716–0.995)	0.750 (0.506–0.904)	–
Specificity (95% CI)	0.875 (0.744–0.947)	0.940 (0.825–0.984)	–
Kappa coefficient (95% CI)*	0.757 (0.595–0.920)	0.711 (0.525–0.897)	0.714
Two-class model			
Psoriasis			
Sensitivity (95% CI)	0.872 (0.650–0.968)	1.000 (0.815–1.000)	–
Specificity (95% CI)	0.838 (0.677–0.932)	0.605 (0.435–0.755)	–
Kappa coefficient (95% CI)*	0.688 (0.502–0.875)	0.529 (0.502–0.875)	0.232

CI: Confidence interval; CNN: Convolutional neural network. * Compared with reference standard.

Figura 6.1: Prestazioni relative allo studio effettuato dal dipartimento di dermatologia del Peking Union Medical College Hospital [48]

Un esempio di quanto succede viene riportato nelle figure 6.2, 6.3, 6.4 e 6.5. Confrontando le figure 6.2 e 6.3, si nota un'estrema somiglianza tra le lesioni cutanee riportate dai due soggetti. Eppure, nel primo caso la label reale è Psoriasi mentre nel secondo caso si tratta di Dermatite Atopica. Il modello, infatti, classifica la prima lesione come Dermatite così come la seconda. Lo stesso errore si ripresenta nella figura 6.4 dove viene mostrato un esempio di immagine relativa alla Psoriasi di tipo Guttate che presenta sintomi molto simili a quelli riportati nella lesione della figura 6.5 appartenente alla classe Dermatite Atopica.



Figura 6.2: Label reale Psoriasi, label predetta Dermatite Atopica



Figura 6.3: Label reale Dermatite Atopica, label predetta Dermatite Atopica



Figura 6.4: Label reale Psoriasi, label predetta Dermatite Atopica



Figura 6.5: Label reale Dermatite Atopica, label predetta Dermatite Atopica

6.1.1 Saliency map

Le immagini presenti nel dataset di Training raccolte da *DermNet* sono dotate di *trademark* mentre quelle prese da *atlansDerm* ne sono sprovviste. Questo può rappresentare una limitazione per le prestazioni del modello. Per scongiurare che il modello raccogliesse informazioni dalla parte di immagine che riguarda il logo sono state calcolate le **saliency map**. Questa tecnica consente di evidenziare le regioni di un'immagine che sono rilevanti per la predizione effettuata dal modello di rete neurale. Le aree in cui vi è la maggior concentrazione di informazioni utili vengono colorate in rosso scendendo di gradazione fino alle aree meno coinvolte riportate in blu. Nella figura 6.6 è evidente come il modello non si concentri sulla regione di immagine dove è presente il logo, infatti, in corrispondenza di quell'area il colore visibile nella saliency map è un blu intenso.




Figura 6.6: Esempio di Psoriasi con trademark e la sua relativa saliency map

Altra criticità del dataset è la presenza di alcune immagini con sfondo nero e altre dove l'area d'interesse occupa l'intero spazio disponibile. Si è ritenuto necessario valutare tramite saliency map se questa caratteristica di alcune immagini influenzasse o meno il modello. Nella figura 6.7 si nota un esempio di una lesione di Dermatite Atopica riportata su sfondo nero e osservando la saliency map è possibile notare come le zone di sfondo sono quelle che hanno una gradazione di blu più intenso. Questo evidenzia come la rete classifica le aree nere come quelle meno rappresentative.




Figura 6.7: Esempio di Dermatite Atopica con sfondo nero e la sua relativa saliency map

6.2 Possibili sviluppi futuri

La limitazione principale per lo sviluppo del progetto è stata la scarsa numerosità del dataset di training. Aumentando la rappresentazione delle diverse tipologie di Psoriasi e Dermatite Atopica le prestazioni del modello dovrebbero incrementare. Ulteriore possibilità per migliorare le performance sarebbe la validazione da parte di un dermatologo esperto della classificazione delle immagini di training. Infatti, le performance ottenute dai dermatologi nello studio del Peking Union Medical College Hospital riportate in figura 6.1 ci suggeriscono che la stessa classificazione delle immagini utilizzate per il training del modello potrebbe riportare degli errori dovuti all'esperienza sulle varie tipologie di lesione da parte di chi ha effettuato la classificazione.

Gli sviluppi futuri del progetto potrebbero includere diverse direzioni per migliorare l'app e arricchire l'esperienza degli utenti. Alcune possibili aree di sviluppo potrebbero essere:

- **Aggiunta di nuove condizioni della pelle:** espandere il database delle condizioni della pelle riconosciute dall'app includendo una maggiore varietà di malattie, disturbi e problematiche cutanee in modo da coprire un'ampia gamma di possibili diagnosi correlate all'Acne, Psoriasi e Dermatite Atopica;
- **Supporto per lingue diverse:** : offrire l'app in più lingue per rendere l'esperienza accessibile a una vasta gamma di utenti in tutto il mondo;
- **Integrazione di funzionalità di telemedicina:** consentire agli utenti di connettersi con medici e dermatologi in remoto tramite l'app per ottenere consulenze e consigli personalizzati sulla cura della pelle;
- **Monitoraggio a lungo termine:** implementare una funzionalità di monitoraggio a lungo termine per consentire agli utenti di tenere traccia delle condizioni della loro pelle nel tempo e di osservarne eventuali cambiamenti;
- **Educazione e consapevolezza:** integrare una sezione di educazione e consapevolezza sulla salute della pelle all'interno dell'app per aiutare gli utenti a comprendere meglio le condizioni cutanee e ad adottare pratiche preventive;
- **Ottimizzazione dell'interfaccia utente:** migliorare l'esperienza dell'utente ottimizzando l'interfaccia grafica dell'app per renderla più intuitiva, semplice da usare e visivamente attraente;
- **Testing dell'app su diverse piattaforme:** procedere con le operazioni di testing dell'app su diverse piattaforme come iOS o Web garantirebbe l'espansione e il raggiungimento di un pubblico più ampio.

6.3 Riepilogo degli obiettivi raggiunti

Il primo obiettivo dell'elaborato di tesi è stato quello di studiare e approfondire le caratteristiche delle tre malattie della pelle selezionate e la sintomatologia comune, nonché i metodi di supporto diagnostico computer-based e le applicazioni disponibili in campo dermatologico. Questa fase di ricerca ha permesso di ottenere una panoramica completa del contesto di studio.

Ci si è poi focalizzati sulla raccolta, la preparazione e l'elaborazione dei dati necessari per l'addestramento dei modelli. È stato fondamentale selezionare un dataset adeguato, svolgere operazioni di pre-processing e data augmentation, nonché implementare algoritmi di color constancy per migliorare la coerenza cromatica delle immagini.

La terza fase del progetto ha riguardato l'implementazione, l'addestramento e la valutazione delle prestazioni dei modelli di intelligenza artificiale. Sono stati utilizzati e valutati tre diversi modelli: ResNet 50, Inception V3 e MobileNet V2, analizzando le loro prestazioni su immagini originali e filtrate.

Il focus è stato successivamente spostato sullo sviluppo dell'app ADP Skin-Assistant utilizzando Flutter. Gli obiettivi riguardanti la progettazione e lo sviluppo dell'applicazione sono stati centrati sui requisiti dell'interfaccia utente e sull'architettura dell'app.

Infine, ci si è concentrati sul valutare i risultati ottenuti, analizzando le prestazioni dell'app ADP Skin-Assistant e dei modelli implementati. Sono state considerate anche le possibili prospettive future per ulteriori sviluppi e migliorie del progetto. Grazie all'ottenimento di questi obiettivi, con questo progetto si è riusciti a creare un'applicazione per il riconoscimento di alcune malattie cutanee combinando l'intelligenza artificiale con l'interfaccia utente amichevole di Flutter e fornendo così una risorsa potenzialmente utile nel campo della dermatologia digitale.

Bibliografia

- [1] Moolchand Sharma, Bhanu Jain, Chetan Kargeti, Vinayak Gupta e Deepak Gupta. «Detection and diagnosis of skin diseases using residual neural networks (RESNET)». In: *International Journal of Image and Graphics* 21.05 (2021), p. 2140002 (cit. alle pp. 1, 11).
- [2] Hywel C Williams, Robert P Dellavalle e Sarah Garner. «Acne vulgaris». In: *The Lancet* 379.9813 (2012), pp. 361–372 (cit. a p. 3).
- [3] Andrea L Zaenglein. «Acne vulgaris». In: *New England Journal of Medicine* 379.14 (2018), pp. 1343–1352 (cit. alle pp. 3, 4).
- [4] Lizelle Fox, Candice Csongradi, Marique Aucamp, Jeanetta Du Plessis e Minja Gerber. «Treatment Modalities for Acne». In: *Molecules* 21.8 (2016). ISSN: 1420-3049. DOI: 10.3390/molecules21081063. URL: <https://www.mdpi.com/1420-3049/21/8/1063> (cit. a p. 4).
- [5] Christopher E M Griffiths, Peter van de Kerkhof e Magdalena Czarnecka-Operacz. «Psoriasis and Atopic Dermatitis». en. In: *Dermatol Ther (Heidelb)* 7.Suppl 1 (feb. 2017), pp. 31–41 (cit. a p. 5).
- [6] Syeda Fatima Aijaz, Saad Jawaid Khan, Fahad Azim, Choudhary Sobhan Sha-keel e Umer Hassan. «Deep Learning Application for Effective Classification of Different Types of Psoriasis». In: *Journal of Healthcare Engineering* 2022 (gen. 2022), p. 7541583 (cit. a p. 5).
- [7] April W Armstrong et al. «From the Medical Board of the National Psoriasis Foundation: Treatment targets for plaque psoriasis». en. In: *J Am Acad Dermatol* 76.2 (nov. 2016), pp. 290–298 (cit. a p. 5).
- [8] Ashwin Bhanudas Kuchekar, Rohini Revansiddappa Pujari, Shantanu Bha-nudas Kuchekar, Shashikant N. Dhole, Payal M. Mule, Bharti Vidyapeeth e Borhade Wadi. «Psoriasis: A comprehensive review». In: 2011 (cit. a p. 5).
- [9] Dahlia Saleh e Laura S. Tanner. *Guttate Psoriasis*. StatPearls Publishing, Treasure Island(FL), 2022. URL: <http://europepmc.org/books/NBK482498> (cit. a p. 5).

-
- [10] Giuseppe Micali, Anna Verzì, Giorgia Giuffrida, Enrico Panebianco, Maria Musumeci e Francesco Lacarrubba. «Inverse Psoriasis: From Diagnosis to Current Treatment Options». In: *Clinical, Cosmetic and Investigational Dermatology* Volume 12 (gen. 2020), pp. 953–959. DOI: 10.2147/CCID.S189000 (cit. a p. 6).
- [11] Melinda J. Gooderham, Abby S. Van Voorhees e Mark G. Lebwohl. «An update on generalized pustular psoriasis». In: *Expert Review of Clinical Immunology* 15.9 (2019). PMID: 31486687, pp. 907–919. DOI: 10.1080/1744666X.2019.1648209. eprint: <https://doi.org/10.1080/1744666X.2019.1648209>. URL: <https://doi.org/10.1080/1744666X.2019.1648209> (cit. a p. 6).
- [12] Rasnik K Singh et al. «Erythrodermic psoriasis: pathophysiology and current treatment perspectives». en. In: *Psoriasis (Auckl)* 6 (lug. 2016), pp. 93–104 (cit. a p. 6).
- [13] Carmela Avena-Woods. «Overview of atopic dermatitis». In: *The American journal of managed care* 23.8 Suppl (giu. 2017), S115–S123. ISSN: 1088-0224. URL: <http://europepmc.org/abstract/MED/28978208> (cit. a p. 8).
- [14] Rebecca Berke, Arshdeep Singh e Mark Guralnick. «Atopic dermatitis: an overview». In: *American family physician* 86.1 (2012), pp. 35–42 (cit. a p. 8).
- [15] Meagan Barrett e Minnelly Luu. «Differential diagnosis of atopic dermatitis». In: *Immunology and Allergy Clinics* 37.1 (2017), pp. 11–34 (cit. a p. 10).
- [16] Chen Li et al. «Synovitis, acne, pustulosis, hyperostosis and osteitis syndrome: a single centre study of a cohort of 164 patients». In: *Rheumatology* 55.6 (2016), pp. 1023–1030 (cit. a p. 10).
- [17] M Monisha, Alex Suresh e MR Rashmi. «Artificial intelligence based skin classification using GMM». In: *Journal of medical systems* 43 (2019), pp. 1–8 (cit. a p. 11).
- [18] Rifat Sadik, Anup Majumder, Al Amin Biswas, Bulbul Ahammad e Md Mahfujur Rahman. «An in-depth analysis of Convolutional Neural Network architectures with transfer learning for skin disease diagnosis». In: *Healthcare Analytics* 3 (2023), p. 100143 (cit. a p. 11).
- [19] Neil C Thompson, Kristjan Greenewald, Keeheon Lee e Gabriel F Manso. «The computational limits of deep learning». In: *arXiv preprint arXiv:2007.05558* (2020) (cit. a p. 11).
- [20] Jainesh Rathod, Vishal Waghmode, Aniruddh Sodha e Prasenit Bhavathankar. «Diagnosis of skin diseases using Convolutional Neural Networks». In: *2018 second international conference on electronics, communication and aerospace technology (ICECA)*. IEEE. 2018, pp. 1048–1051 (cit. a p. 11).

-
- [21] NZ DermNet. *DermNet NZ website*. 2008. URL: <https://dermnetnz.org/> (cit. alle pp. 11, 16).
- [22] Andrew G Howard, Menglong Zhu, Bo Chen, Dmitry Kalenichenko, Weijun Wang, Tobias Weyand, Marco Andreetto e Hartwig Adam. «Mobilenets: Efficient convolutional neural networks for mobile vision applications». In: *arXiv preprint arXiv:1704.04861* (2017) (cit. alle pp. 11, 30).
- [23] François Chollet. «Xception: Deep learning with depthwise separable convolutions». In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2017, pp. 1251–1258 (cit. a p. 11).
- [24] Philipp Tschandl, Cliff Rosendahl e Harald Kittler. «The HAM10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions». In: *Scientific Data* 5.1 (ago. 2018), p. 180161 (cit. alle pp. 11, 14).
- [25] Jia Deng, Wei Dong, Richard Socher, Li-Jia Li, Kai Li e Li Fei-Fei. «ImageNet: A large-scale hierarchical image database». In: *2009 IEEE Conference on Computer Vision and Pattern Recognition*. 2009, pp. 248–255. DOI: 10.1109/CVPR.2009.5206848 (cit. alle pp. 11, 28).
- [26] Jessica Velasco et al. «A smartphone-based skin disease classification using mobilenet cnn». In: *arXiv preprint arXiv:1911.07929* (2019) (cit. a p. 12).
- [27] Manu Goyal, Thomas Knackstedt, Shaofeng Yan e Saeed Hassanpour. «Artificial intelligence-based image classification methods for diagnosis of skin cancer: Challenges and opportunities». In: *Computers in biology and medicine* 127 (2020), p. 104065 (cit. alle pp. 14, 16).
- [28] A. Youssef, Domenico Bloisi, M. Muscio, A. Pennisi, D. Nardi e A. Facchiano. «Reti Convoluzionali per la Segmentazione di Lesioni Cutanee in Immagini Dermoscopiche». In: *SMART eLAB* 14 (gen. 2020), pp. 50–51. DOI: 10.30441/smart-elab.v14i.111. URL: <https://calliope.cnr.it/index.php/smartelab/article/view/111> (cit. alle pp. 14, 15).
- [29] Saturnino Gasparini, Gian Luigi Giovane e Giulio Ferranti. *Trattato di dermoscopia*. Springer Science & Business Media, 2004 (cit. a p. 15).
- [30] *AtlasDerm website*. URL: <https://www.atlasdermatologico.com.br/> (cit. a p. 16).
- [31] Enes Ayan e Halil Murat Ünver. «Data augmentation importance for classification of skin lesions via deep learning». In: *2018 Electric Electronics, Computer Science, Biomedical Engineerings' Meeting (EBBT)*. 2018, pp. 1–4. DOI: 10.1109/EBBT.2018.8391469 (cit. a p. 17).

- [32] Vivek Agarwal, Besma R Abidi, Andreas Koschan e Mongi A Abidi. «An overview of color constancy algorithms». In: *Journal of Pattern Recognition Research* 1.1 (2006), pp. 42–54 (cit. a p. 20).
- [33] Gershon Buchsbaum. «A spatial processor model for object colour perception». In: *Journal of the Franklin institute* 310.1 (1980), pp. 1–26 (cit. a p. 20).
- [34] Joost Van De Weijer, Theo Gevers e Arjan Gijsenij. «Edge-based color constancy». In: *IEEE Transactions on image processing* 16.9 (2007), pp. 2207–2214 (cit. a p. 20).
- [35] Imanol Bilbao e Javier Bilbao. «Overfitting problem and the over-training in the era of data: Particularly for Artificial Neural Networks». In: *2017 Eighth International Conference on Intelligent Computing and Information Systems (ICICIS)*. 2017, pp. 173–177. DOI: 10.1109/INTELCIS.2017.8260032 (cit. a p. 25).
- [36] JM Casanova, M Baradad, X Soria e RM Martí. «Use of www. dermatoweb. net to Support Undergraduate Teaching of Dermatology». In: *Actas Dermo-Sifiliográficas (English Edition)* 100.10 (2009), pp. 866–874 (cit. alle pp. 26, 44).
- [37] TL Diepgen, Z Tanko, E Weisshaar, A Matvijets e M Simon. «Medical information systems in the internet: Current data about the dermatologic web site www. dermis. net». In: *Der Hautarzt* 60 (2009), pp. 979–983 (cit. alle pp. 26, 44).
- [38] Sheldon Mascarenhas e Mukul Agarwal. «A comparison between VGG16, VGG19 and ResNet50 architecture frameworks for Image Classification». In: *2021 International conference on disruptive technologies for multi-disciplinary research and applications (CENTCON)*. Vol. 1. IEEE. 2021, pp. 96–99 (cit. a p. 27).
- [39] Priyanka Pradhan, Brajesh Kumar e Shashank Mohan. «Comparison of various deep convolutional neural network models to discriminate apple leaf diseases using transfer learning». In: *Journal of Plant Diseases and Protection* 129.6 (2022), pp. 1461–1473 (cit. alle pp. 28, 29).
- [40] Hoo-Chang Shin, Holger R. Roth, Mingchen Gao, Le Lu, Ziyue Xu, Isabella Nogue, Jianhua Yao, Daniel Mollura e Ronald M. Summers. «Deep Convolutional Neural Networks for Computer-Aided Detection: CNN Architectures, Dataset Characteristics and Transfer Learning». In: *IEEE Transactions on Medical Imaging* 35.5 (2016), pp. 1285–1298. DOI: 10.1109/TMI.2016.2528162 (cit. a p. 28).
- [41] Kaiming He, Xiangyu Zhang, Shaoqing Ren e Jian Sun. «Deep residual learning for image recognition». In: *Proceedings of the IEEE conference on computer vision and pattern recognition*. 2016, pp. 770–778 (cit. a p. 29).

- [42] Christian Szegedy, Vincent Vanhoucke, Sergey Ioffe, Jonathon Shlens e Zbigniew Wojna. *Rethinking the Inception Architecture for Computer Vision*. 2015. arXiv: 1512.00567 [cs.CV] (cit. a p. 29).
- [43] Parvathaneni Naga Srinivasu, Jalluri Gnana SivaSai, Muhammad Fazal Ijaz, Akash Kumar Bhoi, Wonjoon Kim e James Jin Kang. «Classification of skin disease using deep learning neural networks with MobileNet V2 and LSTM». In: *Sensors* 21.8 (2021), p. 2852 (cit. alle pp. 30, 31).
- [44] Diederik P Kingma e Jimmy Ba. «Adam: A method for stochastic optimization». In: *arXiv preprint arXiv:1412.6980* (2014) (cit. a p. 33).
- [45] Kevin Koidl. «Loss functions in classification tasks». In: *School of Computer Science and Statistic Trinity College, Dublin* (2013), pp. 1–5 (cit. a p. 34).
- [46] Khan Kalimullah e Donthula Sushmitha. «Influence of design elements in mobile applications on user experience of elderly people». In: *Procedia computer science* 113 (2017), pp. 352–359 (cit. a p. 47).
- [47] Wouter A Alberts e Thea M Van Der Geest. «Color matters: Color as trustworthiness cue in web sites». In: *Technical communication* 58.2 (2011), pp. 149–160 (cit. a p. 48).
- [48] Shi-Qi Wang, Xin-Yuan Zhang, Jie Liu, Cui Tao, Chen-Yu Zhu, Chang Shu, Tao Xu e Hong-Zhong Jin. «Deep learning-based, computer-aided classifier developed with dermoscopic images shows comparable performance to 164 dermatologists in cutaneous disease diagnosis in the Chinese population». In: *Chinese medical journal* 133.17 (2020), pp. 2027–2036 (cit. alle pp. 53, 54).