

# Metoda strojnog učenja za detekciju melanoma na koži mobilnim uređajem

---

**Stojčević, Stjepan**

**Master's thesis / Diplomski rad**

**2024**

*Degree Grantor / Ustanova koja je dodijelila akademski / stručni stupanj: Josip Juraj Strossmayer University of Osijek, Faculty of Electrical Engineering, Computer Science and Information Technology Osijek / Sveučilište Josipa Jurja Strossmayera u Osijeku, Fakultet elektrotehnike, računarstva i informacijskih tehnologija Osijek*

*Permanent link / Trajna poveznica: <https://urn.nsk.hr/urn:nbn:hr:200:304695>*

*Rights / Prava: [In copyright](#)/[Zaštićeno autorskim pravom.](#)*

*Download date / Datum preuzimanja: **2024-12-21***

*Repository / Repozitorij:*

[Faculty of Electrical Engineering, Computer Science  
and Information Technology Osijek](#)



SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU  
FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I  
INFORMACIJSKIH TEHNOLOGIJA OSIJEK

Sveučilišni diplomski studij Računarstvo

METODA STROJNOG UČENJA ZA DETEKCIJU  
MELANOMA NA KOŽI MOBILNIM UREĐAJEM

Diplomski rad

Stjepan Stojčević

Osijek, 2024. godina

SVEUČILIŠTE JOSIPA JURJA STROSSMAYERA U OSIJEKU  
FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA I  
INFORMACIJSKIH TEHNOLOGIJA OSIJEK

Sveučilišni diplomski studij Računarstvo

METODA STROJNOG UČENJA ZA DETEKCIJU  
MELANOMA NA KOŽI MOBILNIM UREĐAJEM

Diplomski rad

Stjepan Stojčević

Mentor: prof. dr. sc. Irena Galić

Sumentor: dr. sc. Marin Benčević

Osijek, 2024. godina

**FERIT**FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA  
I INFORMACIJSKIH TEHNOLOGIJA OSIJEK**Obrazac D1: Obrazac za ocjenu diplomskog rada na sveučilišnom diplomskom studiju****Ocjena diplomskog rada na sveučilišnom diplomskom studiju**

Ime i prezime pristupnika:	Stjepan Stojčević
Studij, smjer:	Sveučilišni diplomski studij Računarstvo
Mat. br. pristupnika, god.	D1326R, 10.10.2022.
JMBAG:	1311030007
Mentor:	prof. dr. sc. Irena Galić
Sumentor:	Marin Benčević, univ. mag. ing. comp.
Sumentor iz tvrtke:	
Predsjednik Povjerenstva:	doc. dr. sc. Krešimir Romić
Član Povjerenstva 1:	Marin Benčević, univ. mag. ing. comp.
Član Povjerenstva 2:	doc. dr. sc. Hrvoje Leventić
Naslov diplomskog rada:	Metoda strojnog učenja za detekciju melanoma na koži mobilnim uređajem
Znanstvena grana diplomskog rada:	<b>Umjetna inteligencija (zn. polje računarstvo)</b>
Zadatak diplomskog rada:	Istražiti i opisati stanje polja analize dermatoloških slika, s naglaskom na klasifikaciju dermatoloških slika. Istražiti i opisati medicinsku pozadinu melanocitnih lezija na koži i dijagnostičke kriterije za melanome. Korištenjem metoda obrade slike razviti metodu koja omogućuje neškolovanim korisnicima slikanje lezije na koži mobilnim uređajem. Korištenjem metoda dubokog učenja razviti algoritam koji na temelju slike i korisnički unesenih podataka o leziji daje procjenu vjerojatnosti da se radi o melanomu. Ispitati algoritam na stvarnim primjerima i dati
Datum ocjene pismenog dijela diplomskog rada od strane mentora:	02.09.2024.
Ocjena pismenog dijela diplomskog rada od strane mentora:	Izvrstan (5)
Datum obrane diplomskog rada:	13.9.2024.
Ocjena usmenog dijela diplomskog rada (obrane):	Izvrstan (5)
Ukupna ocjena diplomskog rada:	Izvrstan (5)
Datum potvrde mentora o predaji konačne verzije diplomskog rada čime je pristupnik završio sveučilišni diplomski studij:	17.09.2024.



**FERIT**

FAKULTET ELEKTROTEHNIKE, RAČUNARSTVA  
I INFORMACIJSKIH TEHNOLOGIJA OSIJEK

## IZJAVA O IZVORNOSTI RADA

Osijek, 17.09.2024.

Ime i prezime Pristupnika:	Stjepan Stojčević
Studij:	Sveučilišni diplomski studij Računarstvo
Mat. br. Pristupnika, godina upisa:	D1326R, 10.10.2022.
Turnitin podudaranje [%]:	6

Ovom izjavom izjavljujem da je rad pod nazivom: **Metoda strojnog učenja za detekciju melanoma na koži mobilnim uređajem**

izrađen pod vodstvom mentora prof. dr. sc. Irena Galić

i sumentora Marin Benčević, univ. mag. ing. comp.

moj vlastiti rad i prema mom najboljem znanju ne sadrži prethodno objavljene ili neobjavljene pisane materijale drugih osoba, osim onih koji su izričito priznati navođenjem literature i drugih izvora informacija.

Izjavljujem da je intelektualni sadržaj navedenog rada proizvod mog vlastitog rada, osim u onom dijelu za koji mi je bila potrebna pomoć mentora, sumentora i drugih osoba, a što je izričito navedeno u radu.

Potpis pristupnika:

# Sadržaj

<b>1. Uvod . . . . .</b>	<b>2</b>
<b>2. Opis problema . . . . .</b>	<b>3</b>
<b>3. Pregled stanja znanosti . . . . .</b>	<b>5</b>
3.1. Medicinska pozadina . . . . .	5
3.1.1. Benigne promjene na koži . . . . .	5
3.1.2. Maligne promjene na koži . . . . .	6
3.1.3. Dijagnosticiranje . . . . .	7
3.2. Tehnička pozadina . . . . .	8
3.2.1. Konvolucijske Neuronske Mreže . . . . .	8
3.2.2. Adamov Algoritam . . . . .	11
3.2.3. TensorFlow . . . . .	12
3.2.4. CreateML . . . . .	15
3.2.5. Swift . . . . .	16
<b>4. Rješenja na tržištu . . . . .</b>	<b>19</b>
4.1. Pregled znanstvene literature . . . . .	19
4.1.1. Detekcija melanoma putem računalnog vida . . . . .	19
4.1.2. Detekcija melanoma s mobilnim uređajima . . . . .	19
4.2. Scanoma: Mobilna Aplikacija za Detekciju Melanoma . . . . .	20
<b>5. Izrada rada . . . . .</b>	<b>22</b>
5.1. Metodologija . . . . .	22
5.1.1. Predobrada Slika . . . . .	22
5.1.2. Opis Skupa Podataka . . . . .	23
5.1.3. Konverzija Modela za Mobilnu Aplikaciju . . . . .	25
5.2. Implementacija . . . . .	26
5.2.1. Glavne komponente aplikacije . . . . .	26
5.2.2. ContentView . . . . .	26
5.2.3. StatsView . . . . .	28
5.2.4. Integracija CoreML modela . . . . .	30
<b>6. Rezultati . . . . .</b>	<b>31</b>
<b>7. Zaključak . . . . .</b>	<b>33</b>
<b>Sažetak . . . . .</b>	<b>37</b>
<b>Abstract . . . . .</b>	<b>38</b>
<b>Životopis . . . . .</b>	<b>39</b>
<b>Popis slika . . . . .</b>	<b>40</b>

## 1. UVOD

Melanom je jedan od najopasnijih vrsta raka kože, ali njegova rana detekcija može značajno povećati šanse za izlječenjem. S razvitkom tehnologije i sveprisutnošću mobilnih uređaja, postoji mogućnost razvijanja alata koji bi omogućili brzu i jednostavnu detekciju melanoma. Cilj ovog diplomskog rada je istražiti metode strojnog učenja koje se mogu primijeniti za detekciju melanoma na koži korištenjem mobilnih uređaja kako bi se i neškolovanim korisnicima omogućilo klasificiranje lezije na koži mobilnim uređajem.

Zadatak mobilne aplikacije je da, nakon što uspješno učita sliku kožne lezije iz galerije, da postotak kolika je vjerojatnost da kožna lezija na odabranoj slici pripada pojedinom tipu kožne lezije. Postotak se dobiva uz pomoć naučenog modela strojnog učenja koji je učen na 10,015 slika kožnih lezija iz javno dostupnog skupa podataka HAM10000 [1]. Za samu klasifikaciju kožnih lezija istrenirana je konvolucijska neuronska mreža koja je optimizirana Adamovim algoritmom. Skup podataka podijeljen je na skupa za treniranje, testiranje i validaciju kako bi se postigli što uspješniji rezultati. Skup za treniranje sadrži 75% od cjelokupnog skupa podataka što je oko 7500 primjeraka, dok skupa za testiranje sadrži oko 2250 primjeraka što je 22,5%, a najmanji skup, ali ne i najmanje bitan je skup za validaciju sa svega 2,5% odnosno oko 250 primjeraka. Tako istreniran model strojnog učenja, konvertiran je u tip čitljiv Xcode alatu u kojemu je implementirana sama mobilna aplikacija. Osim ispisivanja rezultata modela strojnog učenja, mobilna aplikacija nudi unos korisnikovih dodatnih parametara na temelju kojih se ispisuju statistički podaci vezani za melanome i kožne lezije općenito. Na ovaj način, cilj je pružiti alat koji može pomoći u ranom otkrivanju melanoma i time povećati šanse za uspješno ozdravljenje.

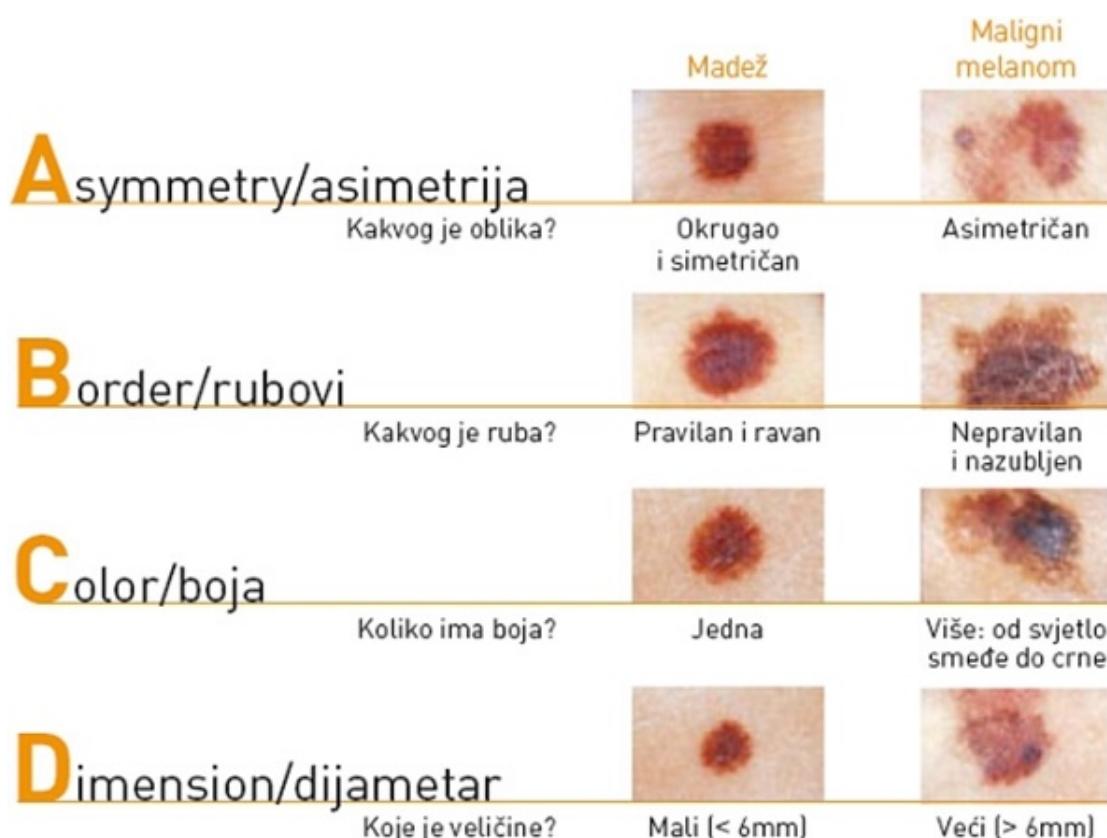
Diplomski rad obuhvaća detaljan opis korištenih metoda, prilagodbu skupa podataka, izgradnju i evaluaciju modela, te razvoj mobilne aplikacije. Rezultati rada pokazuju potencijalnu primjenjivost ovakvih tehnologija u svakodnevnom životu, te ukazuju na mogućnosti proširenja funkcionalnosti i daljnog unapređenja u svrhu povećanja točnosti samog modela.

## 2. OPIS PROBLEMA

Ovaj diplomski rad koristi različite metode i tehnike strojnog učenja kako bi se postigla učinkovita detekcija melanoma na koži korištenjem mobilnog uređaja. U ovom poglavlju opisane su glavne metode i tehnike implementirane u rješenju, uključujući manipulaciju podacima, vizualizaciju, izgradnju modela strojnog učenja i razvoj mobilne aplikacije. Uobičajene metode za praćenje promjena na koži uključuju samopregled i dermatološke preglede.

"Na melanom treba posumnjati kad se na koži pojavi pigmentirana lezija koja raste i širi se. Klinički znakovi na temelju kojih se obično postavi sumnja poznati su po pravilu ABCD.

- **A - asimetrija (engl. asymmetry):** Za razliku od madeža, melanomi su neravne promjene koje se sastoje od raznoraznih dijelova koji cijeloj leziji daju nepravilan oblik.
- **B - rubovi (engl. border):** Rubovi su melanoma nepravilni, nazubljeni ili izbrazdani.
- **C - boja (engl. colour):** Boja može varirati od tamnosmeđe do svjetlosmeđe, žute pa čak i blijede. Promjene često imaju nehomogenu boju.
- **D - dijametar (engl. diameter):** Svaka pigmentirana lezija koja je prerasla debljinu stražnjega dijela obične olovke ( $>6$  mm) mora se ukloniti jer bi mogla biti melanom. Većina melanoma mjeri u promjeru više od 6 mm." [2, p. 687]



SL. 2.1: ABCD pregled. Izvor: [3]

Za manipulaciju i pripremu podataka korištena je biblioteka pandas, koja omogućava jednostavno rukovanje nad prikupljenim podacima. Skup podataka korišten u ovom radu preuzet je s Kaggle servisa i učitan u DataFrame strukturu. Podaci uključuju informacije o različitim tipovima lezija kože, što omogućava klasifikaciju i analizu.

Biblioteke matplotlib i seaborn korištene su za vizualizaciju podataka. Ove biblioteke omogućavaju kreiranje različitih grafova i slika koje pomažu u razumijevanju skupa podataka i rezultata modela. Vizualizacija je ključna za identifikaciju obrazaca u podacima te za prezentaciju rezultata na razumljiv način.

Za izgradnju modela strojnog učenja korištene su biblioteke TensorFlow i Keras. Korištenjem ovih biblioteka izgrađen je i treniran model za klasifikaciju slika melanoma. Model koristi neuronske mreže za prepoznavanje i klasifikaciju različitih tipova lezija kože na temelju slika. Proces treniranja uključuje podešavanje hiperparametara i optimizaciju performansi modela.

Model je treniran na skupu podataka i evaluiran na testnom skupu kako bi se provjerila njegova učinkovitost. Rezultati evaluacije pružaju uvid u to koliko je model uspješan u prepoznavanju melanoma u usporedbi s drugim tipovima lezija.

Mobilna aplikacija razvijena je u Swift programskom jeziku, koristeći razvojno okruženje Xcode. Aplikacija omogućava korisnicima učitavanje slika kože koje se zatim analiziraju pomoću treniranog modela. Aplikacija također omogućava unos dodatnih informacija o madežu i korisnikovim osobnim informacijama, što pomaže u detaljnijoj i preciznijoj analizi rizika.

Mobilna aplikacija pruža korisnicima jednostavan način za praćenje promjena na koži i rano prepoznavanje potencijalno opasnih lezija što može imati ključnu ulogu u ozdravljenju. Integracija modela strojnog učenja unutar aplikacije omogućava automatsku analizu slika, što povećava dostupnost alata za rano otkrivanje melanoma široj populaciji.

Kombinacija ovih metoda i tehnika omogućila je kreiranje sustava koji može učinkovito detektirati melanom na koži koristeći mobilni uređaj, čime se značajno olakšava rana detekcija i povećavaju šanse za uspješno liječenje. Ova tehnologija ima potencijal da postane vrijedan alat u borbi protiv raka kože, omogućavajući brzu i pristupačnu analizu rizika za svakog korisnika.

### **3. PREGLED STANJA ZNANOSTI**

#### **3.1. Medicinska pozadina**

Koža je najveći ljudski organ. Većina ljudi tijekom života uoči na svojoj koži promjene različitih boja, oblika i izgleda. Veliki dio tih novonastalih promjena čine benigni madeži, međutim liječnici predlažu da se svaka novonastala promjena na koži izloženoj suncu pregleda zbog sumnje na melanom. Postoji nekoliko vrsta raka kože, ali se općenito dijele na benigne i maligne. Benigne promjene su neinvazivne, ne šire se na druge dijelove tijela i obično nisu opasne po život. Najčešći primjer benignih promjena su madeži nevusi, dok su najčešći maligni tumori bazocelularni karcinom te planocelularni karcinom. Melanom je rijed oblik malignog tumora kože, međutim najopasniji je oblik zbog svog potencijala za brzo širenje na druge dijelove tijela. Razlikovanje benignih promjena od melanoma predstavlja izazov u dijagnostici. Ključ uspješnog liječenja melanoma je rano detektiranje, a upravo zbog svoje sličnosti u izgledu s benignim nevusima, često se ne otkrije na vrijeme. Liječnici pri postavljanju sumnje na melanom koriste se takozvanom abecedom melanoma, odnosno ABCD pravilom. Ukoliko madež ispunjava kriterije ABCD pravila koje je objašnjeno u poglavljju 'Opis Problema' ovog rada, osoba se upućuje na biopsiju. Rezultati biopsije jedini su stopostotno precizni i točni kriteriji za razlikovanje benignih i malignih promjena.<sup>[4]</sup>

"Melanom je zločudni tumor koji se razvija iz pigmentnih stanica melanocita, a zbog velike sklonosti ranom limfogenom i hematogenom metastaziranju ubraja se među najagresivnije zločudne tumore kože i sluznica." [5, p. 123]

Melanom je najopasniji oblik raka kože, odgovoran za većinu smrtnih slučajeva povezanih s rakom kože. Iako čini samo mali postotak svih karcinoma kože, melanom ima visoku sklonost metastaziranju, što ga čini izuzetno smrtonosnim. Čimbenici rizika uključuju izlaganje UV zračenju, genetsku predispoziciju te prisutnost brojnih i neobičnih madeža. Rana dijagnoza i pravodobno liječenje ključni su za poboljšanje ishoda kod pacijenata s melanomom. Preventivne mjere, poput redovitog pregleda kože i korištenja zaštitnih sredstava protiv sunca, mogu značajno smanjiti rizik od razvoja melanoma.

##### **3.1.1 Benigne promjene na koži**

U benigne tumore kože s poremećajem pigmentacije ubrajaju se tipični i atipični madeži nevusi, dermatofibromi, seborične keratoze te kapilarne malformacije, odnosno hemangiomi. Aktiničke keratoze su prekancerozne lezije, ali samo njihovo postojanje ubraja se u skupinu benignih promjena.

Nevusi su pigmentirane makule, papule ili čvorovi građeni od nakupina melanocita, stanica koje proizvode melanin. Oni izgledom najviše sliče melanomu, međutim nisu agresivni, ne invadiraju dublje slojeve kože i potkožja te ne metastaziraju. Većina madeža su bezopasni, ali neki mogu postati displastični odnosno nepravilni te povećati rizik od razvoja melanoma. Također, broj madeža na tijelu veći od 50 povećava šanse za razvoj melanoma tijekom života. Nevuse dijelimo u nekoliko skupina: spojni nevus, složeni nevusi, intradermalni nevus, halo nevus te plavi nevus. Razlikuju se po svom izgledu i smještaju u koži, ali svima je zajednička dobroćudnost.

Dermatofibromi su tvrde, crvene do smeđe male papule ili čvorići, građeni od fibroblastičnog tkiva. Obično se pojavljuju na donjim ekstremitetima, ali se mogu pojaviti i na drugim dijelovima tijela. Češći su kod žena, a uzrok je vjerojatno genetski. Promjene su obično od 0,5 do 1 cm, na opip su tvrde, a na postranični pritisak mogu se ulegnuti. Većina ne uzrokuje simptome, no neki mogu uzrokovati svrbež ili ulceracije nakon manje traume.

Seboroične keratoze su površinske, u većini slučajeva hiperpigmentirane epitelne promjene. Obično su bradavičaste, ali mogu se pojaviti i u obliku glatkih papula. Ove promjene najčešće se stvaraju u starijoj životnoj dobi. Najčešće mjesto pojave je trup i sljepoočnice. Ove benigne keratoze su različitih veličina i sporo rastu. Mogu biti okrugle ili ovalne, boje kože, smeđe ili crne boje. Čvrsto su vezane uz podlogu, a površina im može imati bradavičast, ljuskast ili hrapav izgled.

Kapilarne malformacije najčešće se javljaju kod novorođenčadi i djece, ali u rijetkim slučajevima mogu se pojaviti i u odrasloj dobi. Te promjene su najčešće plosnatog, ružičastog, crvenog ili ljubičastog izgleda. Nastaju zbog abnormalnog nakupljanja krvnih žila. Dijelimo ih na površinske, duboke te kombinirane hemangiome koji imaju i površinske i duboke komponente. Većina vaskularnih lezija ne uzrokuje simptome, međutim u rijetkim slučajevima može doći do ulceracije ili ometanja funkcije pojedinih organa u čijoj su blizini smješteni.

Aktinična keratoza je prekancerozna keratotična promjena. Posljedica je višegodišnjeg opetovanog izlaganja suncu. Obično su ružičaste ili crvene boje, slabo ograničene te grube i ljuskave na dodir, a mogu biti sive ili smeđe boje. Osobito su im sklene osobe sa svijetлом ili crveno kosom, plavim očima te svijetlijom puti.

### 3.1.2 Maligne promjene na koži

Rak kože najčešća je vrsta raka u ljudi, a većina slučajeva nastaje na dijelovima tijela izloženima suncu. Incidencija je najveća u osoba koje rade na otvorenom, sportaša i osoba koje se sunčaju, a obrnuto je razmjerna količini melaninske pigmentacije kože odnosno najpodložniji su osobe svijetle puti. Najčešći oblici su bazocelularni karcinom, karcinom pločastih stanica i melanom, dok su manje česti oblici Pagetova bolest bradavice, Kaposijev sarkom, karcinom Merkelovih stanica, atipični fibroksantom, tumori adneksa te kožni limfom T stanica.

Rak kože u početku je često asimptomatski, a najčešće se očituje u vidu nepravilne crvene ili hiperpigmentirane lezije koja ne cijeli.

Maligni melanom nastaje iz melanocita u pigmentiranog području (koža, sluznice, oči ili središnji živčani sustav).

Melanom je izrazito agresivan oblik raka kože, a faktori rizika za razvoj ove maligne promjene su: izlaganje suncu; izlaganje ultraljubičastom zračenju; nemelanomskih tumor kože; obiteljska i osobna anamneza; svijetla put; pjege; atipični madeži; povećan broj melanocitnih nevusa; imunosupresija; prisutnost atipičnih madeža.

4 glavna oblika melanoma su: površinsko šireći melanom, nodularni melanom, lentigo maligna melanom te akrálni lentiginozni melanom. Razlikuju se po svom izgledu te položaju na tijelu.

Bazocelularni karcinom je površinska, spororastuća papula ili čvor. Potječe od stanica epidermisa. Rijetko metastazira, ali lokalni rast može biti vrlo destruktivan. Najčešći oblici su: nodularni, površinski, morfeiformni i pigmentirani. Nodularni bazocelularni karcinomi su čvrsti, sjajni, mali i gotovo prozirni do ružičasti čvorići s teleagniektažijama, obično na licu. Površinski karcinomi bazalnih stanica pojavljuju se u obliku crvenih ili ružičastih tankih papula ili plakova, najčešće na trupu. Morfeiformni bazocelularni karcinomi pojavljuju se kao plosnati, indurirani plakovi koji nalikuju na ožiljak. Pigmentirani bazocelularni karcinomi nastaju iz stanica koje proizvode pigment.

Planocelularni karcinom ili karcinom pločastih stanica jest zloćudni tumor epidermalni keratinocita koji prodire u dermis, a obično nastaje na područjima izloženim suncu. Lokalno uzrokuje opsežnu destrukciju, a u kasnim stadijima može metastazirati. Razvija se na normalnom tkivu ili na području leukoplakije, ožiljku od opeklina, a može nastati i progresijom iz aktiničke keratoze. [6]

### **3.1.3 Dijagnosticiranje**

Kao što je već prethodno opisano, svaka promjena sumnjiva izgleda upućuje se na biopsiju. Stručnjaci se za probir promjena koje treba uputiti na biopsiju koriste abecedom melanoma. Na temelju samog izgleda promjene, ne može se dati sigurna dijagnoza, već samo postaviti opravdavana sumnja. Pri pregledu lezija, dermatolozi se koriste dermatoskopom. To je medicinski instrument koji omogućuje liječnicima da bolje vizualiziraju strukture u gornjim slojevima kože koje nisu vidljive golim okom. Dermatoskopi imaju povećanje od 10 do 20 puta. Moderni dermatoskopi uključuju i značajke poput polarizirane i nepolarizirane svjetlosti, digitalnog snimanja visoke rezolucije i softverske integracije za analizu i pohranu podataka. Ove napredne funkcije dodatno poboljšavaju dijagnostičke sposobnosti i omogućuju precizniju i detaljniju procjenu kožnih lezija.

Biopsijom liječnici uzimaju dio kožne lezije ili čitavu promjenu te taj uzorak šalju na patohistološku analizu. Patohistološka analiza omogućuje uvid u vrstu i karakteristike stanica koje sudjeluju u gradi same lezije. Tek takva analiza, sa sigurnošću će utvrditi o kojoj promjeni na koži je riječ.

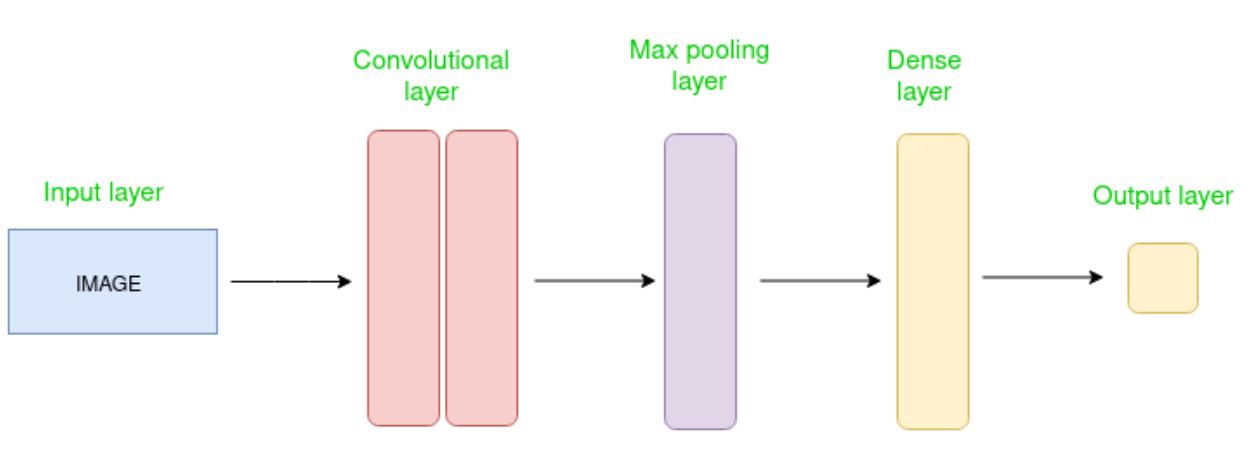
## 3.2. Tehnička pozadina

### 3.2.1 Konvolucijske Neuronske Mreže

Konvolucijske neuronske mreže (CNN) su vrsta arhitekture dubokih neuronskih mreža koja se često koristi u računalnom vidu. Računalni vid je područje umjetne inteligencije koje omogućuje računalu da razumije i interpretira vizualne podatke. Kada je riječ o strojnom učenju, umjetne neuronske mreže su jako korisne i primjenjive. Neuronske mreže koriste se na raznim skupovima podataka poput slika, audiozapisa i teksta. Različite vrste neuronskih mreža koriste se za različite svrhe, primjerice za predviđanje niza riječi koristimo rekurentne neuronske mreže, preciznije LSTM, dok za klasifikaciju slika koristimo konvolucijske neuronske mreže.

"CNNs se najčešće primjenjuju na slike (eng. image data) koje su matrice piksela i predstavljaju se svojom širinom, visinom i vrednostima piksela. Za slike u boji, svaki od 3 kanala (RGB) se uobičajeno predstavlja vrednostima piksela u opsegu 0-255. RGB slika se predstavlja 3D strukturom, koja se zove ulazna zapremina (eng. input volume)." [7]

U klasičnoj neuronskoj mreži postoje tri vrste slojeva: ulazni sloj, skriveni slojevi i izlazni sloj. Ulazni sloj je sloj u kojem unosimo podatke u naš model. Broj neurona u ovom sloju jednak je ukupnom broju značajki u našim podacima odnosno broj piksela u slučaju slike. Skriveni sloj prima ulazne podatke iz ulaznog sloja. Može postojati mnogo skrivenih slojeva, ovisno o modelu i veličini podataka. Svaki skriveni sloj može imati različit broj neurona, koji su obično veći od broja značajki. Izlaz iz svakog sloja izračunava se matričnim množenjem izlaza prethodnog sloja s težinama koje se mogu učiti u tom sloju i dodavanjem pomaka koje se mogu učiti, a zatim primjenom aktivacijske funkcije koja mrežu čini nelinearnom. Izlazni sloj prima izlaz iz skrivenog sloja i koristi logističku funkciju poput sigmoida ili softmaxa koja pretvara izlaz svake klase u vjerojatnosni rezultat svake klase.



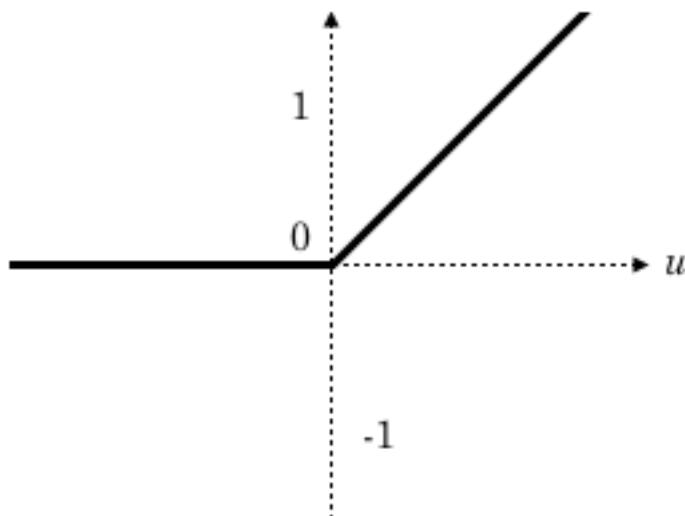
SL. 3.2: Schema Konvolucijskih Neuronskih Mreža. Izvor: [8]

Konvolucijske neuronske mreže se sastoje od nekoliko ključnih slojeva:

- **Konvolucijski sloj:** Primjenjuje filtre na ulazne slike kako bi izvukao značajke. Svaki filter prelazi preko slike i izračunava rezultat u obliku značajki koje prikazuje prisutnost određenih obrazaca u slici.
- **Sloj aktivacije:** Dodaje nelinearnost mreži primjenom funkcije aktivacije poput ReLU (engl. Rectified Linear Unit), koja postavlja sve negativne vrijednosti na nulu i ostavlja pozitivne vrijednosti nepromijenjene.

- **Sloj uzorkovanja (engl. Pooling):** Smanjuje dimenzije mape značajki kako bi se smanjila računska složenost i spriječilo prekomjerno učenje. Najčešći tipovi su maksimalno uzorkovanje (engl. Max Pooling), koje uzima najveću vrijednost u svakom patchu slike, i prosječno uzorkovanje (engl. Average Pooling).
- **Potpuno povezani sloj:** Nakon nekoliko konvolucijskih i uzorkovnih slojeva, značajke se izravnavaju u vektor i ulaze u jedan ili više potpuno povezanih slojeva koji donose konačne odluke o klasifikaciji.

$$f(u) = \max(0, u)$$



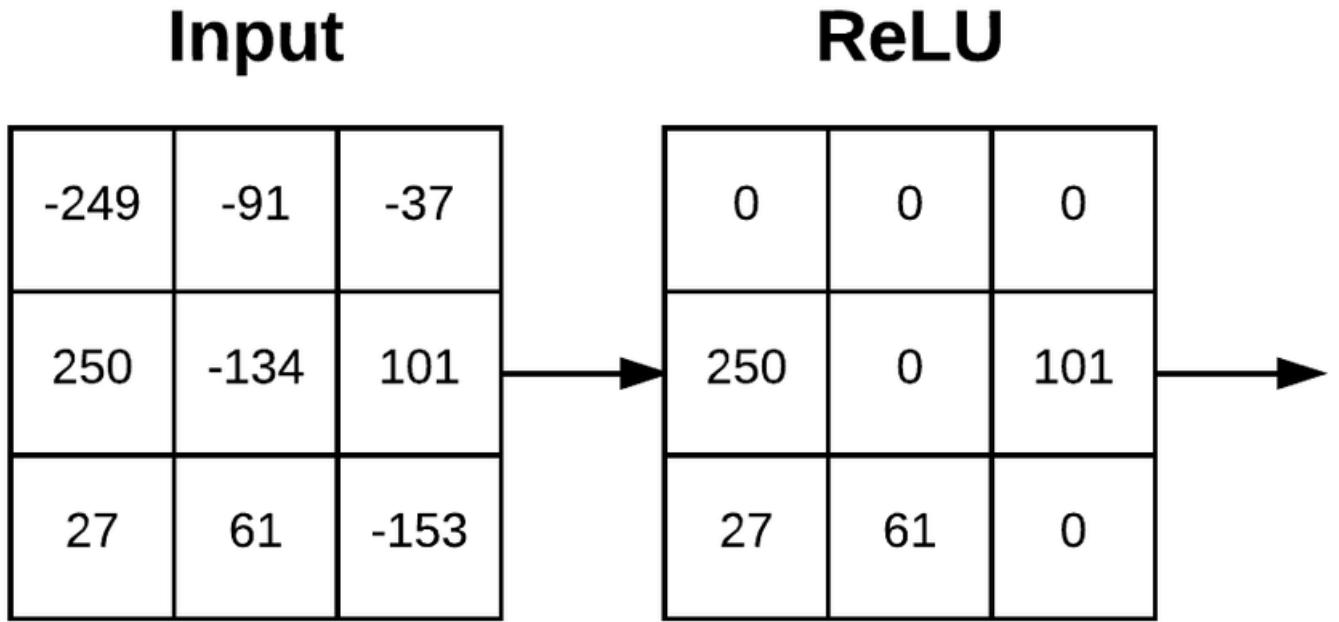
**SL. 3.3:** Aktivacijska funkcija ReLu. Izvor: [9]

U nastavku su objašnjene neke od bitnijih prednosti i neki nedostatci korištenja ReLu aktivacijske funkcije. "Prednosti:

- **Gradijent bez zasićenja:** ReLU funkcija nema zasićenje za pozitivne vrijednosti, što pomaže u ublažavanju problema nestajanja gradijenta. To omogućuje bržu i učinkovitiju obuku dubokih mreža.
- **Računalna učinkovitost:** ReLU je računalno učinkovit jer uključuje jednostavno postavljanje praga na nulu.
- **Rijetka aktivacija:** ReLU ima tendenciju proizvoditi rijetke aktivacije, što znači da će za određeni ulaz mnogi neuroni dati nulu. To može dovesti do učinkovitije mreže i može pomoći u ublažavanju problema prekomjernog opremanja.

Nedostaci:

- **Problem umiranja ReLU:** Jedan potencijalni problem s ReLU-om je problem "umirućeg ReLU-a", gdje neuroni mogu postati neaktivni i izlaze samo nula za svaki ulaz. To se može dogoditi ako veliki gradijent teče kroz ReLU neuron, uzrokujući ažuriranje težina na takav način da se neuron nikada više ne aktivira.
- **Neograničeni izlaz:** Izlaz ReLU-a je neograničen za pozitivne ulaze, što ponekad može dovesti do eksplodirajućih aktivacija ako se njima pravilno ne upravlja tehnikama poput normalizacije serije." [10]



**SL. 3.4:** Djelovanje aplikacijske *ReLU* funkcije na sliku koja je zapisana u matričnom obliku.

Izvor: [\[11\]](#)

U nastavku je dio koda napisan za svrhe ovog diplomskog rada u kojemu je prikazan primjer jednostavne implementacije konvolucijske neuronske mreže koristeći TensorFlow i Keras:

#### Primjer koda 1: Implementacija CNN-a

```

1 import tensorflow as tf
2 import pandas as pd
3 import keras
4 from keras.models import Sequential
5 from keras.layers import Dense, Dropout
6 from keras.models import Sequential
7 from sklearn.model_selection import train_test_split
8
9 df = pd.read_csv('archive/HAM10000_metadata.csv')
10 features=df.drop(columns=['cell_type_idx'],axis=1)
11 target=df['cell_type_idx']
12 x_train_o, x_test_o, y_train_o, y_test_o = train_test_split(features, target,
    ↪ test_size=0.25,random_state=666)
13 model = Sequential()
14 model.add(Dense(units= 64, kernel_initializer = 'uniform', activation = 'relu',
    ↪ input_dim = 37500))
15 model.add(Dense(units= 64, kernel_initializer = 'uniform', activation = 'relu'))
16 model.add(Dense(units= 64, kernel_initializer = 'uniform', activation = 'relu'))
17 model.add(Dense(units= 64, kernel_initializer = 'uniform', activation = 'relu'))
18 model.add(Dense(units = 7, kernel_initializer = 'uniform', activation = 'softmax'))
19
20 optimizer = tf.keras.optimizers.Adam(learning_rate = 0.00075,
```

```

21         beta_1 = 0.9,
22         beta_2 = 0.999,
23         epsilon = 1e-8)
24
25     model.compile(optimizer = optimizer, loss = 'categorical_crossentropy', metrics = [
26         'accuracy'])
27
28     history = model.fit(x_train, y_train, batch_size = 10, epochs = 47)

```

Ovaj kod je korišten u razvijanju modela strojnog učenja za svrhu ovog diplomskog rada. HAM10000 skup podataka sadrži 10000 slika raspoređenih u 7 klasa. Nazivi tih klasa su : "Benign keratosis-like lesions", "Melanocytic nevi", "Dermatofibroma", "Melanoma", "Vascular lesions", "Basal cell carcinoma", "Actinic keratoses". Model se trenira kroz 47 epoha i koristi se za klasifikaciju slika madeža. Proces uključuje normalizaciju slikevnih podataka, definiranje slojeva CNN-a, kompajliranje modela, treniranje i validaciju.

### 3.2.2 Adamov Algoritam

Optimizatori su algoritmi ili metode koje se koriste kako bi zamijenili odnosno poboljšali hiperparametre neuronskih mreža kao što su stopa učenja, težina sloja i slično.

"Adam optimizacija je metoda stohastičkog gradijentnog spusta koja se zasniva na adaptivnoj procjeni prvog i drugog momenta."[\[12\]](#) Razvijen je kao unaprijeđenje klasičnih algoritama poput stohastičke gradijentne metode i nudi kombinaciju prednosti iz drugih metoda optimizacije kao što su AdaGrad [\[13\]](#) i RMSProp [\[14\]](#).

Neke od glavnih prednosti ovog optimizacijskog algoritma su činjenice da je on "računalno učinkovit, ima male zahtjeve za memorijom, nepromjenjiv na dijagonalno skaliranje gradijenata i dobro je prikladan za probleme koji su veliki u smislu podataka/parametara."[\[15\]](#)

Adam koristi procjene prvog i drugog momenta gradijenata za prilagodbu stope učenja. Prvi moment predstavlja prosjek gradijenata što je identično kao kod Momentum metode, dok drugi moment predstavlja prosjek kvadrata gradijenata što je slično kao u RMSProp algoritmu. Kombiniranjem ovih tehnika, Adam osigurava stabilnije i brže konvergiranje u procesu optimizacije. Adam održava dva pokretna prosjeka za gradijente,  $m_t$  (procjena prvog momenta) i  $v_t$  (procjena drugog momenta):

$$m_t = \beta_1 m_{t-1} + (1 - \beta_1) g_t \quad (3-1)$$

$$v_t = \beta_2 v_{t-1} + (1 - \beta_2) g_t^2 \quad (3-2)$$

gdje su  $\beta_1$  i  $\beta_2$  hiperparametri koji kontroliraju eksponencijalno raspadanje stopa za te trenutke. Tipične vrijednosti za  $\beta_1$  i  $\beta_2$  su 0.9 i 0.999, respektivno. Kako bi se uklonile pristranosti (bias correction), Adam koristi korigirane procjene trenutaka:

$$\hat{m}_t = \frac{m_t}{1 - \beta_1^t} \quad (3-3)$$

$$\hat{v}_t = \frac{v_t}{1 - \beta_2^t} \quad (3-4)$$

Konačna formula za ažuriranje parametara je:

$$\theta_{t+1} = \theta_t - \alpha \frac{\hat{m}_t}{\sqrt{\hat{v}_t} + \epsilon} \quad (3-5)$$

gdje je  $\alpha$  stopa učenja, a  $\epsilon$  vrlo mali broj koji sprječava dijeljenje s nulom pa je iz tog razloga njegova vrijednost najčešće jednaka  $10^{-8}$ .

Adam optimizator možete proslijediti kao vrijednost niza `adam` argumentu `optimizer` funkcije `model.compile` na sljedeći način:

```
model.compile(optimizer="adam")
```

Ova metoda prosljeđuje `adam` optimizator funkciji sa zadanim vrijednostima za betas i stopu učenja. Možete koristiti klasu `Adam` dostupnu u `tf.keras.optimizers`.

Sintaksa je sljedeća:

```
Adam(learning_rate, beta_1, beta_2, epsilon, amsgrad, name)
```

Slijedi opis parametara navedenih gore:

- **learning\_rate**: Stopa učenja koja se koristi u algoritmu. Zadana vrijednost je 0.001.
- **beta\_1**: Vrijednost za eksponencijalnu stopu raspadanja za procjenu prvog momenta. Zadana vrijednost je 0.9.
- **beta\_2**: Vrijednost za eksponencijalnu stopu raspadanja za procjenu prvog momenta. Zadana vrijednost je 0.999.
- **epsilon**: Konstantan broj koji služi za numeričku stabilnost. Zadana vrijednost je 1e-7.
- **amsgrad**: Bool vrijednost koja specificira hoće li se primijeniti AMSGrad varijanta ovog algoritma. Zadana vrijednost je False.
- **name**: Opcionalno ime za operacije kreirane prilikom primjene gradijenata. Zadana vrijednost je "Adam".

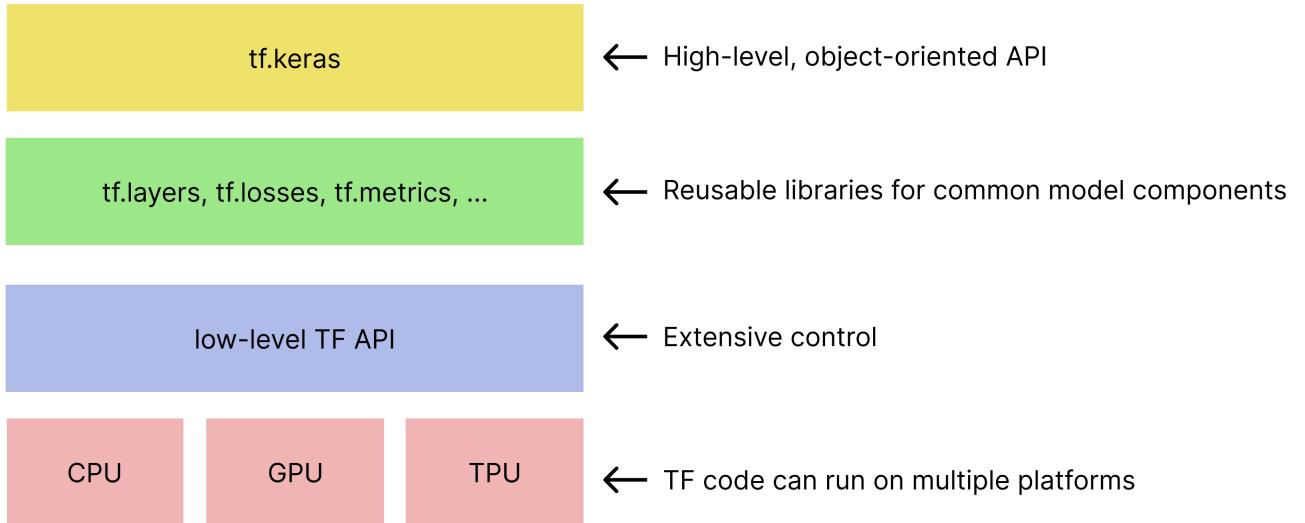
### 3.2.3 TensorFlow

TensorFlow[16] je popularni okvir otvorenog koda za strojno učenje i duboko učenje koji je razvio Google Brain tim, a prvi put je predstavljen 2015. godine. Ovaj okvir omogućava istraživačima i developerima jednostavno i učinkovito kreiranje i treniranje modela strojnog učenja. Zahvaljujući svojoj fleksibilnosti i skalabilnosti, pogodan je za razne aplikacije, od istraživačkih projekata do proizvodnih sustava.

Korisnicima se pruža mogućnost izgradnje i prilagodbe modela koristeći različite razine apstrakcije. Osnovni API omogućava detaljan pristup operacijama i grafovima, dok visokorazinski API, poput Keras-a[17], omogućava brzo i jednostavno kreiranje modela. Keras API je postao vrlo popularan zbog svoje jednostavnosti i intuitivnog dizajna, čineći ga idealnim za početnike, ali i za iskusne istraživače koji žele brzo iterirati i eksperimentirati s različitim modelima.

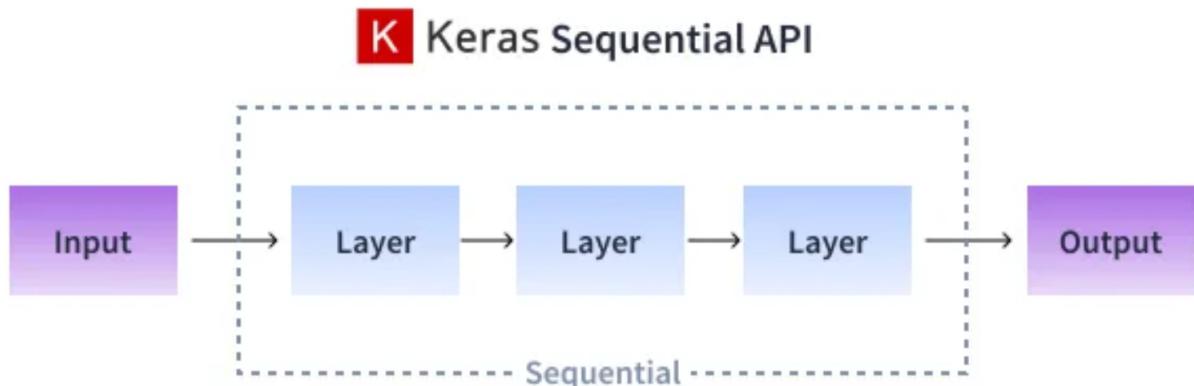
TensorFlow podržava različite platforme za treniranje i izvođenje modela, uključujući CPU, GPU i TPU (Tensor Processing Units). Grafičke kartice omogućavaju ubrzanje treniranja modela koristeći paralelno procesiranje, dok TPU-ovi, specijalno razvijeni od strane Google-a, nude još brže performanse za specifične zadatke dubokog učenja. Ova fleksibilnost omogućava skalabilnost od malih uređaja poput mobitela do velikih distribuiranih sustava u podatkovnim centrima.

`tf.keras.Sequential` je klasa u TensorFlow-u koja omogućava jednostavno kreiranje modela strojnog učenja. Ova klasa je dio visokorazinskog API-ja Keras, koji je dizajniran da omogući



**SL. 3.5:** Hierarchy of TensorFlow components. Source: [18]

brzo i intuitivno kreiranje modela strojnog učenja. Sequential model je linearни niz slojeva, gdje svaki sloj ima točno jedan ulazni i jedan izlazni element. Korištenje Sequential klase je idealno za jednostavne modele kod kojih su slojevi poredani jedan za drugim zbog čega se često koristi za izgradnju potpuno povezanih mreža, konvolucijskih mreža (CNN) i jednostavnih rekurentnih mreža (RNN).



**SL. 3.6:** Sequential API. Source: [19]

Sequential model se može kreirati na dva načina: dodavanjem slojeva prilikom inicijalizacije ili korištenjem metode add(). Prilikom inicijalizacije, model se može definirati na način korišten u razvijanju ovog rada:

#### **Primjer koda 2:** Definiranje Sequential modela(način 1.)

```

1 model = Sequential([
2     Dense(64, activation='relu', kernel_initializer = 'uniform', input_dim = 37500),
3     Dense(64, activation='relu', kernel_initializer = 'uniform'),
4     Dense(64, activation='relu', kernel_initializer = 'uniform'),
5     Dense(64, activation='relu', kernel_initializer = 'uniform'),
6     Dense(7, activation='softmax')
7 ])

```

Alternativno, slojeve možemo dodavati postupno koristeći metodu add():

#### **Primjer koda 3:** Definiranje Sequential modela(način 2.)

```

1 model = Sequential()
2 model.add(Dense(units= 64, kernel_initializer = 'uniform', activation = 'relu',
3                 ↪ input_dim = 37500))
4 model.add(Dense(units= 64, kernel_initializer = 'uniform', activation = 'relu'))
5 model.add(Dense(units= 64, kernel_initializer = 'uniform', activation = 'relu'))
6 model.add(Dense(units = 7, kernel_initializer = 'uniform', activation = 'softmax'))

```

U oba primjera, model se sastoji od pet slojeva: ulaznog sloja i tri skrivena sloja s ReLU aktivacijskom funkcijom te izlaznog sloja sa softmax aktivacijskom funkcijom za klasifikaciju. Nakon definiranja modela, potrebno ga je kompajlirati kako bi se mogao trenirati. Metoda compile omogućava specificiranje optimizatora, funkcije gubitka i metrike koju ćemo pratiti tijekom treniranja:

#### **Primjer koda 4:** Metoda Compile

```

1 model.compile(optimizer = optimizer, loss ='categorical_crossentropy', metrics = [
2     ↪ accuracy])

```

Metoda fit() koristi se za treniranje modela na podacima:

#### **Primjer koda 5:** Metoda Fit

```

1 history = model.fit(x_train, y_train, batch_size = 10, epochs = 47)

```

Za procjenu performansi modela na testnom skupu podataka koristi se metoda evaluate():

#### **Primjer koda 6:** Metoda Evaluate

```

1 accuracy = model.evaluate(x_test, y_test, verbose=1)[1]

```

Za predikciju izlaza na temelju ulaznih podataka koristi se metoda predict():

#### **Primjer koda 7:** Metoda Predict

```

1 predictions = model.predict(test_image)

```

Svi prijašnji primjeri koda su korišteni u izradi modela strojnog učenja koji se koristi za ovaj diplomski rad.

Sequential model je jednostavan za korištenje i idealan za početnike u strojnom učenju. Omogućava brzo postavljanje modela, eksperimentiranje s različitim arhitekturama i poboljšanje performansi modela uz minimalne promjene bez potrebe za dubokim razumijevanjem TensorFlow-a. Zbog svoje jednostavnosti, Sequential model se široko koristi u obrazovnim i istraživačkim okruženjima.

### 3.2.4 CreateML

CreateML je alat za strojno učenje razvijen od strane Applea, koji omogućuje jednostavno kreiranje, treniranje i evaluaciju modela strojnog učenja na Mac računalima. Ovaj alat je posebno koristan za developerke koji žele koristiti strojno učenje u svojim privatnim aplikacijama, ali nemaju veliko iskustvo s tradicionalnim alatima za strojno učenje. CreateML je dobro integriran sa Swift programskim jezikom i Xcode razvojnim okruženjem, što omogućuje jednostavno kreiranje i implementaciju modela strojnog učenja direktno u iOS, macOS, watchOS i tvOS aplikacije.

CreateML podržava različite vrste modela kao što su modeli za klasifikaciju slika, prepoznavanje objekata, analizu teksta i modeli za regresiju. Podaci koji se koriste za treniranje modela mogu biti u različitim formatima, uključujući JSON, CSV i slike. CreateML pruža intuitivno sučelje za uvoz i pripremu podataka, što olakšava rad korisnicima.

Jedna od značajnih prednosti CreateML-a je grafičko sučelje koje omogućava vizualizaciju procesa treniranja modela. Developeri mogu pratiti napredak treniranja, performanse modela i jednostavno prilagođavati hiperparametre. CreateML koristi hardverske mogućnosti Mac računala, uključujući grafičke kartice, kako bi ubrzao proces treniranja modela. To omogućava brže i efikasnije treniranje u usporedbi s nekim drugim alatima.

Još jedan značajan aspekt CreateML-a je mogućnost jednostavne pretvorbe TensorFlow modela u Core ML format, koji je kompatibilan s Appleovim platformama. Ovo je ključna funkcionalnost za developerke koji koriste TensorFlow za treniranje modela, ali ih trebaju implementirati unutar iOS aplikacija. Pretvorba modela omogućuje bržu integraciju i upotrebu strojnog učenja na Appleovim uređajima bez potrebe za ponovnim treniranjem modela u drugom okruženju. Nakon treniranja, model se može izvesti u Core ML format i koristiti unutar aplikacija razvijenih u Xcodeu, što pojednostavljuje proces implementacije modela u stvarne aplikacije. Treniranjem modela na lokalnom računalu osigurava se veća privatnost podataka, što je ključno za aplikacije koje se bave osjetljivim informacijama.

CreateML omogućuje developerima da kreiraju, treniraju i evaluiraju modele strojnog učenja bez potrebe za pisanjem velike količine koda, čime se strojno učenje približava i onima koji nemaju veliko iskustvo u ovom području. Pored toga, CreateML značajno ubrzava proces implementacije strojnog učenja u aplikacije, osiguravajući jednostavan prijelaz od treniranja do implementacije u stvarnim proizvodima. [20]

"Kako biste mogli programirati u jeziku Swift, morate koristiti operativni sustav OS X koji se isporučuje na svim Mac računalima. Jedini softverski paket koji će vam za to biti potreban je Xcode (verzija 7 ili novija). To je radno okruženje koje pruža Apple i koje potpomaže razvoj aplikacija za njihovu platformu." [21, p. 3]

Xcode je integrirano razvojno okruženje (IDE) koje je Apple kreirao kako bi olakšao razvoj softvera na macOS platformi. Prvi put je predstavljen 2003. godine, a od tada je postao ključni alat za izradu aplikacija za sve Appleove platforme, uključujući iOS, macOS, watchOS i tvOS.

Xcode nudi kompletan set alata za dizajniranje, razvoj, testiranje i distribuciju aplikacija. Podržava rad s različitim programskim jezicima kao što su Swift, Objective-C i C++. Njegovo korisničko sučelje je osmišljeno tako da omogućuje efikasan rad programerima, uz funkcional-

nosti poput naprednog editora koda, vizualnog uređivača sučelja (Interface Builder), simulatora za testiranje aplikacija na različitim uređajima te alata za profiliranje performansi aplikacija.

Jedna od ključnih prednosti Xcode-a je njegova integracija s Appleovim ekosustavom. Pomoću Xcode-a, programeri mogu testirati aplikacije direktno na fizičkim uređajima, koristiti alate poput XCTest-a za automatizirano testiranje te upravljati procesom pripreme i distribucije aplikacija putem App Store Connect-a.

Xcode također uključuje Swift Playgrounds, alat namijenjen posebno početnicima, koji omogućuje učenje i eksperimentiranje sa Swift programskim jezikom na interaktivan način. Kroz Swift Playgrounds, korisnici mogu brzo testirati kod i odmah vidjeti rezultate, što ubrzava proces učenja.

Xcode se redovito ažurira kako bi podržao najnovije verzije Appleovih operativnih sustava i donosi nova poboljšanja u performansama i funkcionalnostima. Zbog toga je nezamjenjiv alat za sve koji razvijaju softver za Appleove uređaje. [22]

### 3.2.5 Swift

"Swift je programski jezik koji su razvili u tvrtci Apple kako bi programerima omogućili učinkovitije programiranje za svoju platformu. To je pokušaj da se razvoj aplikacija za iOS, OSX, watchOS i tvOS učini modernijim, sigurnijim i snažnijim. Međutim Apple je swift objavio kao projekt otvorenog izvornog koda i započeo s uvodenjem podrške za Linux, sa ciljem da Swift učini još boljim, općenamjenskim programskim jezikom koji će biti dostupan svugdje" [21, p. 1]

Swift je programski jezik koji je dizajniran tako da bude jednostavan za učenje i korištenje, ali dovoljno moćan za profesionalne programere koji rade na kompleksnim projektima. Sintaksa Swifta je intuitivna i pregledna, što ga čini privlačnim kako za početnike, tako i za iskusne developere.

Bez obzira na to što je Swift potpuno novi programski jezik koji se pojavio u Apple zajednici, još uvijek nije u potpunosti zamijenio Objective-C programski jezik. Programski jezik Swift dizajniran je tako da se može koristiti zajedno s programskim jezikom Objective-C tako da će njihova koegzistencija zasigurno potrajati.

Swift se odlikuje velikom brzinom i efikasnošću. Apple je posebno isticao kako Swift omogućuje brže izvršavanje koda u odnosu na Objective-C, što je od posebne važnosti za aplikacije koje zahtijevaju visoke performanse. Pored toga, Swift koristi automatsko upravljanje memorijom putem Automatic Reference Counting (ARC), što značajno smanjuje rizik od grešaka vezanih za curenje memorije, čime se dodatno povećava sigurnost koda.

Jedna od inovacija koje Swift donosi su opcionalni tipovi, koji omogućuju eksplisitno rukovanje vrijednostima koje mogu biti 'nil'. Ovaj koncept smanjuje mogućnost grešaka prilikom rada s podacima, jer programeri moraju jasno definirati kako će se nositi s takvim situacijama. Swift podržava različite paradigme programiranja, uključujući objektno-orientirano, funkcionalno i imperativno programiranje, što ga čini fleksibilnim alatom za širok spektar primjena.

Swift je potpuno integriran u Appleovo razvojno okruženje Xcode, koje nudi brojne alate za razvoj, uključujući Swift Playgrounds za interaktivno učenje i testiranje koda. Otvoreni karakter Swifta, nakon što je postao open-source 2015. godine, omogućio je njegovu upotrebu i izvan Appleovog ekosustava, posebno u razvoju web aplikacija i server-side rješenja.

Danas je Swift široko prihvaćen u razvoju softvera, ne samo na Appleovim platformama, već i šire u IT sektor, zbog svoje brzine, sigurnosti i jednostavnosti upotrebe. Zbog ovih karakteristika, Swift se smatra jednim od najperspektivnijih programskih jezika današnjice, s velikim potencijalom za daljnji razvoj i inovacije u softverskoj industriji. [23]

Ovdje je prikazan primjer Swift koda korištenog za aplikaciju koja koristi ‘Text‘, ‘PhotosPicker‘, ‘Button‘, i ‘NavigationLink‘ za interakciju s korisnikom:

**Primjer koda 8: Primjer Swift koda**

```
1 Text("molesscope")
2     .font(.custom("Copperplate", size: 36))
3     .foregroundColor(.blue)
4     .padding(.top, 50)
5
6 PhotosPicker("Choose image from gallery", selection: $avatarItem, matching: .images)
7     .padding()
8     .background(Color.black.opacity(0.1))
9     .cornerRadius(10)
10    .font(.headline)
11    .foregroundColor(.black)
12
13 if let avatarImage {
14     avatarImage
15     .resizable()
16     .scaledToFill()
17     .frame(width: 200, height: 200)
18     .clipShape(Circle())
19     .clipped()
20     .transition(.scale)
21 }
22
23 Button(action: {
24     withAnimation {
25         classifyImage()
26     }
27 }) {
28     Text("Check your mole. Good Luck!")
29     .padding()
30     .background(Color.green)
31     .foregroundColor(.white)
32     .cornerRadius(10)
33     .font(.headline)
34     .shadow(color: Color.green.opacity(0.3), radius: 5, x: 0, y: 3)
35 }
36     .padding(.top, 20)
37
38 if showResults {
39     Text(classificationResult)
40     .padding()
41     .background(Color.black.opacity(0.05))
42     .cornerRadius(10)
43     .font(.footnote)
44     .transition(.slide)
45     .lineLimit(nil)
46 }
```

```
47
48 Spacer()
49
50 NavigationLink(destination: StatsView(age: $age, gender: $gender, moleGrowing:
    ↪ $moleGrowing, moleSize: $moleSize, eyeColor: $eyeColor, hairColor: $hairColor,
    ↪ additionalStats: $additionalStats, moleLocation: $moleLocation, familyHistory:
    ↪ $familyHistory)) {
51     Text("Enter Additional Info")
52         .padding()
53         .background(Color.blue)
54         .foregroundColor(.white)
55         .cornerRadius(10)
56         .font(.headline)
57     }
58     .padding(.bottom, 20)
```

## 4. RJEŠENJA NA TRŽIŠTU

### 4.1. Pregled znanstvene literature

#### 4.1.1 Detekcija melanoma putem računalnog vida

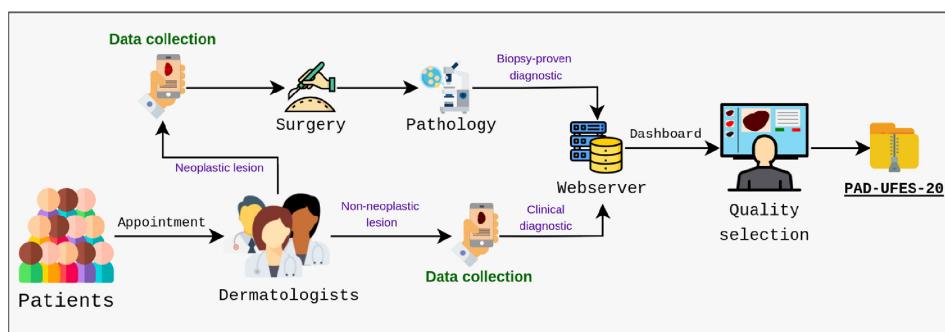
"Pojava novih tehnoloških alata, posebice konvolucijskih neuronskih mreža (CNN-ova), omogućila je automatiziranu dijagnozu raznih kožnih bolesti na temelju slike, čime se revolucionariziralo rano otkrivanje u dermatologiji" [24].

Razvoj računalnog vida, posebno kroz primjenu strojnog učenja i dubokih neuronskih mreža, predstavlja ključni napredak u području klasifikacija kožnih lezija. Modeli dubokog učenja, naročito konvolucijske neuronske mreže, pokazali su da su učinkoviti u prepoznavanju složenih obrazaca u medicinskim slikama te razlikovanju malignih od benignih lezija s visokom točnosti. Esteva i suradnici [25] pokazali su kako konvolucijska neuronska mreža trenirana na preko 130.000 slika kožnih lezija može doseći razinu dijagnostičke točnosti koja se može usporediti s točnošću koju imaju dermatolozi.

U istraživanju objavljenom u *Journal of Signal Processing Systems* [26], uspoređene su performanse različitih arhitektura konvolucijskih neuronskih mreža za detekciju melanoma, s naglaskom na mehanizam pažnje. Pomoću mehanizma pažnje modeli strojnog učenja fokusiraju se na najbitnije i ključne dijelove slike čime se povećava točnost rezultata čak i kad se koriste manji skupovi podataka. Studija Haenssle i suradnika [27] također je pokazala da modeli strojnog učenja mogu pomoći dermatolozima u složenijim slučajevima dijagnosticiranja melanoma, omogućujući dermatolozima da koriste ove alate kao podršku prilikom donošenja konačne dijagnoze, posebno u slučajevima kada nisu sigurni o tipu kožne lezije.

#### 4.1.2 Detekcija melanoma s mobilnim uređajima

Mobilni uređaji postaju bitna pomagala u dijagnostici melanoma zahvaljujući sve većoj dostupnosti i sve boljim i kvalitetnijim kamerama koje se neprestano razvijaju. Trenutno, kamere mobilnih uređaja još uvijek nisu na razini specijalizirane dermatološke opreme, ali mogu pomoći dermatologu u donošenju konačne odluke. Istraživanje objavljeno u *BMJ* [28] pokazuje da aplikacije koje koriste strojno učenje postaju sve učinkovitije u procjeni rizika od melanoma na temelju fotografija snimljenih mobilnim uređajima, bez obzira na činjenicu da su te fotografije slabije kvalitete od dermatoloških fotografija.



SL. 4.7: Prikaz prikupljanja uzoraka za PAD-UFES-20 skup podatka. Izvor: [29]

PAD-UFES-20 [30] je javno dostupan skup podataka koji sadrži slike kožnih lezija prikupljene mobilnim uređajem. Svaka slika iz ovog skupa podataka sadrži i bitne kliničke podatke o pacijentu uključujući demografske podatke poput dobi, spola, pušačkih navika i obiteljske povijesti raka. Prikupljanje podataka organizirano je kroz Dermatološki i Kirurški Asistencijski Program (PAD) na Federalnom sveučilištu Espírito Santo (UFES) u Brazilu, koji pruža besplatnu medicinsku skrb, posebice ljudima s niskim primanjima u ruralnim područjima. PAD-UFES-20 sadrži ukupno 2298 slika kožnih lezija od 1373 pacijenta. Uslikane kožne lezije klasificirane su ukupno u šest kategorija : tri vrste raka kože (bazocelularni karcinom, skvamozni karcinom i melanom) te tri uobičajene benigne lezije (aktinična keratoza, seboroična keratoza i melanocitni nevus).

Sve slike su neobrađene i prikupljene su pomoću raznih modela mobilnih uređaja, što ovaj skup podataka čini vrlo realističnim za stvarne uvjete primjene u medicinskoj praksi s ograničenim resursima. Zbog svoje širine i obujma PAD-UFES-20 predstavlja vrijedan resurs za istraživače koji razvijaju sustave za dijagnozu melanoma u udaljenim područjima gdje je pristup dermatolozima ograničen. Osim toga, PAD-UFES-20 sadrži dermatološke podatke prikupljene biopsijom koji čine 58,4% od ukupnog broja uzoraka. Dermatološki primjeri prikupljeni biopsijom donose veliku točnost onom skupu podataka što ga čini pouzdanim za obuku modela strojnog učenja koji trebaju razlikovati maligne od benignih lezija. U nadolazećim godinama, očekuje se da će se dataset proširiti s dodatnim uzorcima i kliničkim podacima, čime će dodatno pridonijeti istraživanjima u ovom području.

## 4.2. Scanoma: Mobilna Aplikacija za Detekciju Melanoma

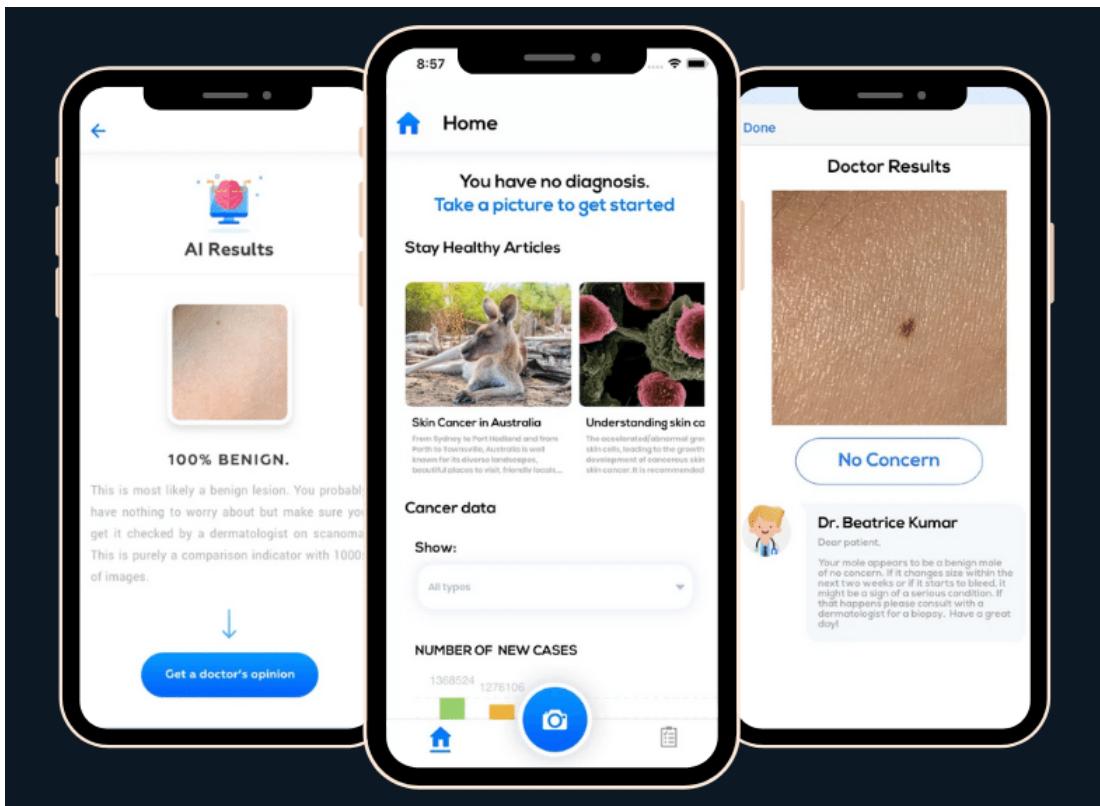
Scanoma je mobilna aplikacija osmišljena kako bi pomogla korisnicima u ranom otkrivanju melanoma i drugih kožnih lezija. Aplikacija koristi napredne algoritme strojnog učenja za analizu slika kože, pružajući korisnicima jednostavan i pristupačan način za praćenje zdravlja svoje kože.

Korisnici mogu snimiti ili učitati slike svojih madeža ili kožnih lezija putem aplikacije. Scanoma koristi algoritme strojnog učenja za analizu slika, identificirajući karakteristike koje mogu ukazivati na melanom ili druge kožne probleme. Aplikacija primjenjuje ABCD test za procjenu rizika od melanoma. Ovaj test uključuje analizu asimetrije, granica, boje, promjera i evolucije madeža. Na temelju ovih kriterija, aplikacija pruža korisnicima povratne informacije o potencijalnom riziku.

Scanoma također omogućava korisnicima praćenje promjena na koži tijekom vremena. Korisnici mogu spremati slike i bilješke o svojim madežima, što im pomaže u praćenju bilo kakvih promjena koje se mogu pojaviti. Aplikacija osigurava visoku razinu privatnosti i sigurnosti podataka. Svi korisnički podaci i slike su enkriptirani i pohranjeni na siguran način. Također, korisnici mogu postaviti podsjetnike za redovne preglede svoje kože, što ih potiče na kontinuirano praćenje i rano otkrivanje promjena.

Jedna od glavnih prednosti Scanoma aplikacije je njena jednostavnost korištenja i dostupnost na mobilnim uređajima, što omogućava korisnicima da jednostavno i brzo analiziraju svoje madeže bilo gdje i bilo kada. Intuitivno sučelje aplikacije čini je lakom za korištenje, čak i za korisnike bez tehničkog predznanja. Rana detekcija melanoma značajno povećava šanse za uspješno liječenje. Scanoma pruža alat koji korisnicima omogućava prepoznavanje rizičnih lezija u ranoj fazi, čime se povećava mogućnost za pravovremenu medicinsku intervenciju.

Kroz korištenje aplikacije, korisnici se educiraju o važnosti praćenja svojih madeža i prepoznavanju znakova melanoma. Aplikacija pruža informacije i savjete o tome kako prepoznati opasne promjene na koži. Osim toga, Scanoma je pristupačna široj populaciji jer ne zahtijeva posjet liječniku za svaku sumnjivu leziju. Ovo može biti posebno korisno za ljude koji žive u



**SL. 4.8:** Scanoma mobilna aplikacija za detekciju melanoma. Izvor: [31]

udaljenim područjima ili imaju ograničen pristup dermatološkim uslugama.

Scanoma koristi napredne algoritme strojnog učenja i računalne vizije za analizu slika kože. Proces rada aplikacije uključuje nekoliko koraka. Prvo, korisnik snimi ili učita sliku lezije putem aplikacije. Aplikacija zatim obavlja preprocesiranje slike kako bi poboljšala kvalitetu i izdvojila relevantne značajke. Nakon toga, algoritam strojnog učenja analizira sliku koristeći prethodno trenirane modele koji su razvijeni na velikim skupovima podataka kožnih lezija. Algoritam identificira karakteristike koje mogu ukazivati na prisutnost melanoma. Na kraju, aplikacija pruža korisniku povratne informacije o analizi, uključujući rizik od melanoma na temelju ABCD testa i drugih kriterija. Korisnik može spremiti rezultate analize i postaviti podsjetnike za buduće preglede. Aplikacija također omogućava praćenje promjena na koži tijekom vremena.

Scanoma predstavlja značajan napredak u području digitalne dermatologije, nudeći korisnicima jednostavan i učinkovit način za praćenje zdravlja kože. Integracijom naprednih algoritama strojnog učenja i intuitivnog mobilnog sučelja, Scanoma omogućava ranu detekciju melanoma, čime potencijalno spašava živote i poboljšava zdravstvene ishode. Kroz edukaciju korisnika i omogućavanje kontinuiranog praćenja, ova aplikacija doprinosi boljoj svijesti o važnosti prevencije i rane detekcije raka kože.

## 5. IZRADA RADA

### 5.1. Metodologija

Metode i pristupi korišteni za detekciju melanoma na koži pomoću mobilnog uređaja opisani su kako bi se omogućilo repliciranje istraživanja temeljem navedenih koraka. Podaci korišteni u ovom istraživanju prikupljeni su iz javno dostupnog skupa podataka, konkretno iz HAM10000[1] skupa podataka. Ovaj skup podataka sadrži slike kožnih lezija s pripadajućim oznakama. Skup podataka uključuje slike različitih tipova lezija, a to su : melanocitne nevi, melanome, benigni keratoze, bazocelularni karcinom, aktinične keratoze, vaskularne lezije i dermatofbrome.

#### 5.1.1 Predobrada Slika

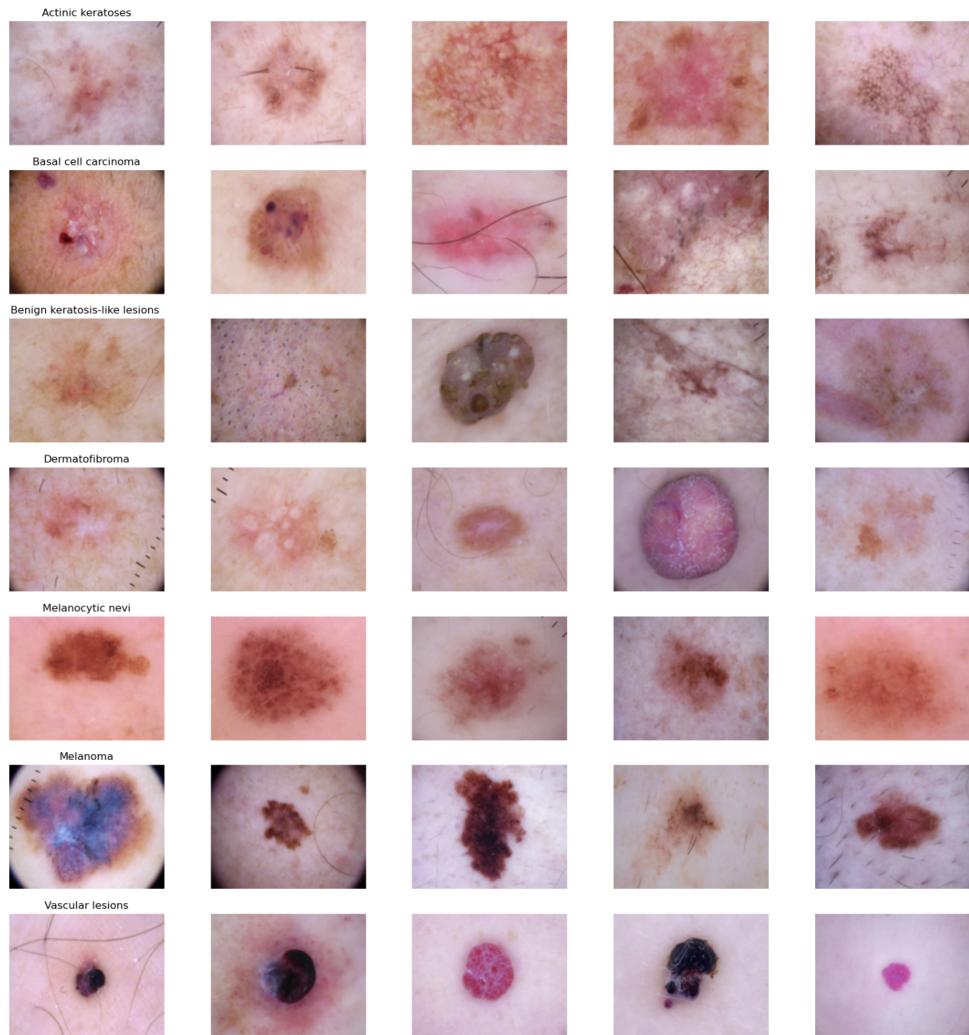
Skup podataka HAM10000[1] sadrži ukupno 10,015 slika koje su označene s pripadajućim dijagnozama. Svaka slika je povezana s ostalim podacima koje preciznije opisuju svakog pacijenta kao što su dob, spol, lokalizacija lezije i dijagnoza. Podaci su učitani iz CSV datoteke koja sadrži sve ove informacije.

Slike su promijenjene veličine na 125x100 piksela kako bi se smanjila računalna složenost i omogućila brža obrada na mobilnim uređajima. Svaka slika je normalizirana tako da pikseli imaju vrijednosti između 0 i 1. Uz to, uklonjeni su svi nepotpuni zapisi (npr. zapisi s nepoznatim spolom ili dobom), čime se osiguralo da model uči na kvalitetnom skupu podataka.

Svaka pojedina slika je transformirana u jednodimenzionalni niz piksela s ukupno 37,500 elemenata (125x100x3) što je omogućilo da slika bude prikladna za unos u neuronsku mrežu.

### 5.1.2 Opis Skupa Podataka

U svrhu dobivanja boljih performansi modela strojnog učenja, skup podataka se uz pomoć `matplotlib` alata vizualizirao kako bi ga bolje razumjeli. Na sljedećim slikama bit će prikazani odnosi između pojedinih čimbenika koji svaku sliku dodatno opisuje. Prikaz uzoraka svake vrste lezije može se vidjeti na slici 5.9.



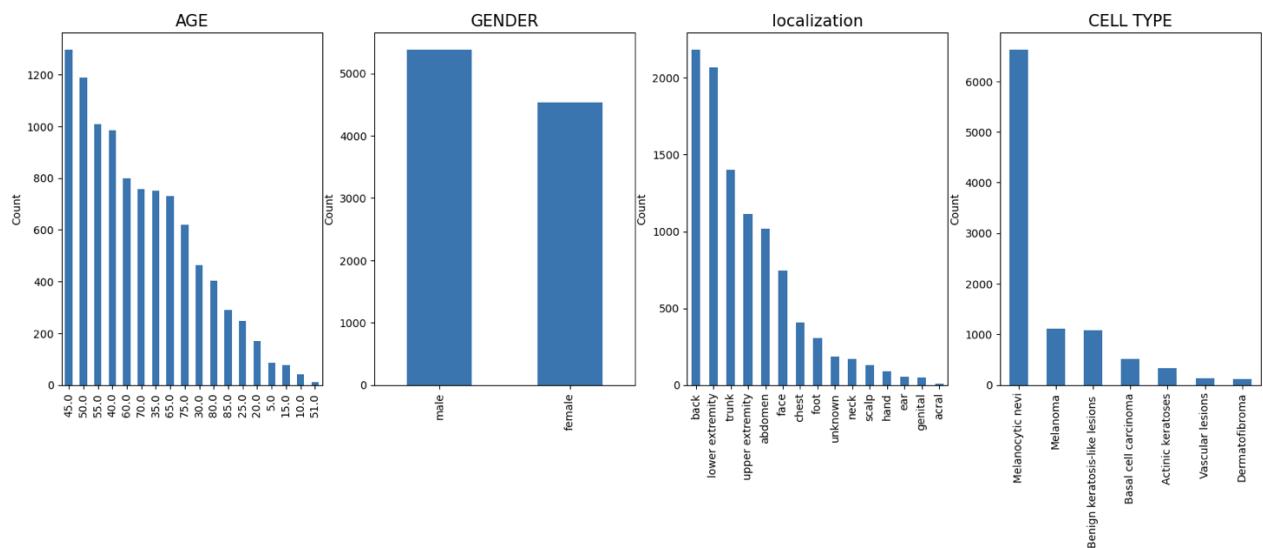
SL. 5.9: Prikaz skupa podataka (pet primjera za svaki tip), snimljeno iz Jupyter Notebooka

Uz to, analizirana je distribucija dobi, spola, lokalizacija i tipa lezija unutar skupa podataka. U svrhu pravilnije distribucije skupa podataka, kako bi neuronska mreža preciznije klasificirala pojedinu sliku kožne lezije iz skupa za validaciju ili testnog skupa. Rezultati analize prikazani su na slici 5.10.

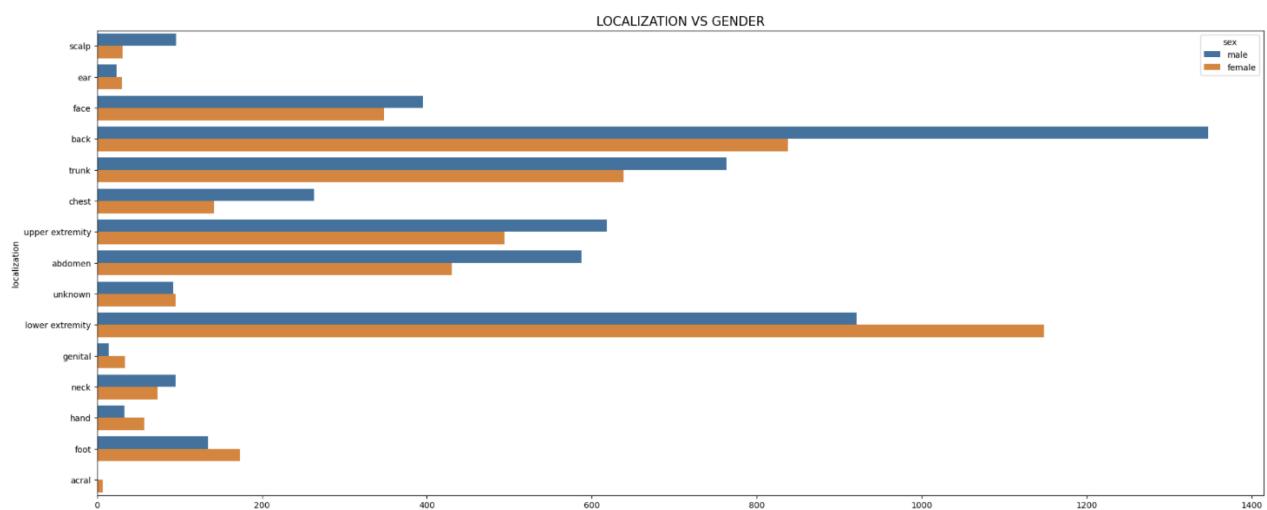
Na temelju tih analiza postavljeni su pragovi koji su korišteni u mobilnoj aplikaciji kako bi korisnici dobili personalizirane informacije o riziku. Ovdje su opisani razlozi za svaku od odluka.

Grafovi su pokazali da muškarci češće razvijaju melanom na leđima, licu, trupu i rukama, dok žene češće razvijaju melanom na nogama, leđima i licu (slika 5.11). Ove informacije podržavaju odluku da aplikacija upozori muške korisnike na povećan rizik smrtnog ishoda melanoma, jer muškarci češće obolijevaju od melanoma na lokacijama koje su teže uočljive bez pomoći liječnika.

Nadalje, osobe s crvenom, plavom ili svijetlom kosom te plavim, zelenim ili sivim očima imaju smanjenu razinu melanina, što smanjuje prirodnu zaštitu kože od UV zračenja.



SL. 5.10: Prikaz skupa podataka (*dob, spol, lokacija, tip*), snimljeno iz Jupyter Notebooka



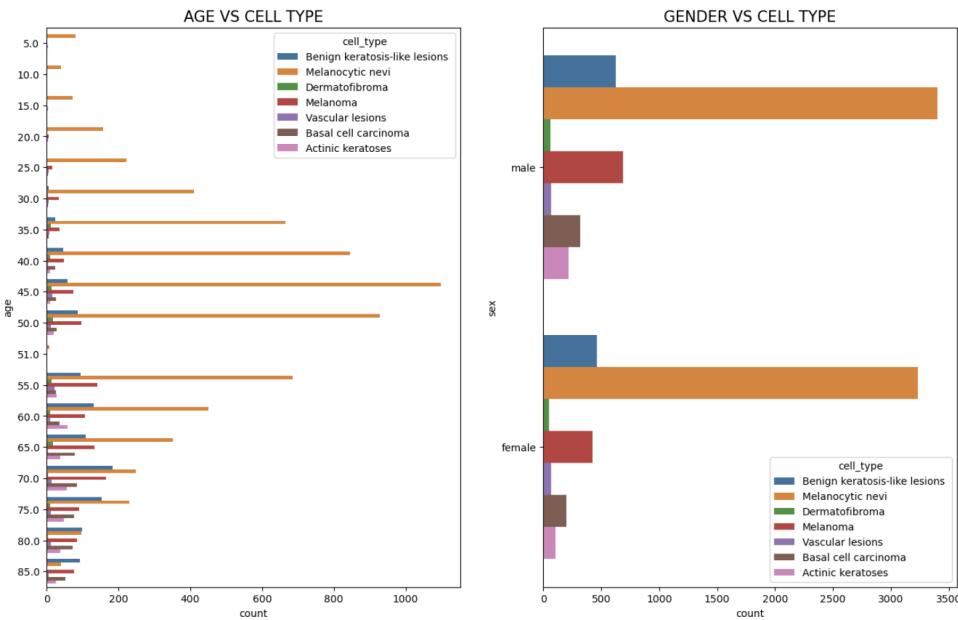
SL. 5.11: Prikaz skupa podataka (*odnos lokacija i spola*), snimljeno iz Jupyter Notebooka

Slika 5.12 prikazuje distribuciju različitih tipova lezija po dobnim skupinama i spolu. Iz tog razloga, aplikacija uključuje pragove vezane uz boju kose i očiju kako bi korisnicima pružila dodatne informacije o riziku.

Podaci pokazuju da su madeži veći od 6 mm i madeži koji rastu skloniji biti maligni. Stoga je prag u aplikaciji postavljen na 6 mm kako bi korisnici mogli biti upozoren na madeže koji prelaze ovu veličinu. Dodatno, rast madeža je bitan indikator da je madež maligni pa upravo iz tog razloga aplikacija prikazuje upozorenje ako korisnik primijeti rast madeža.

Stariji korisnici imaju povećan rizik od razvoja melanoma, osobito nakon 50. godine života, kao što je prikazano u distribuciji dobi i tipova lezija. Zbog toga je dob od 50 godina postavljena kao prag za dodatne preporuke unutar aplikacije.

Nadalje, obiteljska anamneza ima snažan utjecaj na rizik od melanoma. Osobe s obiteljskom poviješću raka kože su u većem riziku, što je uzeto u obzir pri definiranju pragova za personalizirane informacije. Uzimajući u obzir sve ove analize, pragovi postavljeni u aplikaciji osiguravaju relevantne i personalizirane informacije korisnicima, što može doprinijeti ranijoj detekciji i prevenciji melanoma.



**SL. 5.12:** Prikaz skupa podataka (dob i spol s tipom), snimljeno iz Jupyter Notebooka

### 5.1.3 Konverzija Modela za Mobilnu Aplikaciju

Nakon treniranja u TensorFlow okruženju, model je pretvoren u CoreML format kako bi se mogao koristiti na iOS uređajima. Pretvorba je provedena koristeći biblioteku `coremltools`, pri čemu je trenirani TensorFlow model konvertiran u CoreML model i spremljen u formatu `.mlpackage`. Ovaj model je zatim integriran u iOS aplikaciju, omogućujući lokalnu analizu slika kožnih lezija bez potrebe za vanjskom obradom.

Kod za konverziju modela izgledao je ovako:

#### Primjer koda 9: Konverzija modela

```

1 import coremltools
2 from keras.models import load_model
3
4 model = load_model('model.h5')
5 coreml_model = coremltools.convert(model)
6 coreml_model.save('model.mlpackage')]
```

CoreML model, koji je treniran za prepoznavanje različitih tipova lezija kože, integriran je u aplikaciju. Funkcija `createImageClassifier()` inicijalizira model i postavlja konfiguraciju za izvršenje na CPU. Model prihvata ulazne podatke u obliku `MLMultiArray` strukture, koja se generira iz slike korisnika.

Klasifikacijski model koristi unaprijed trenirane težine za različite kategorije lezija, a nakon predikcije, rezultati se formatiraju u čitljiv oblik za prikaz korisniku.

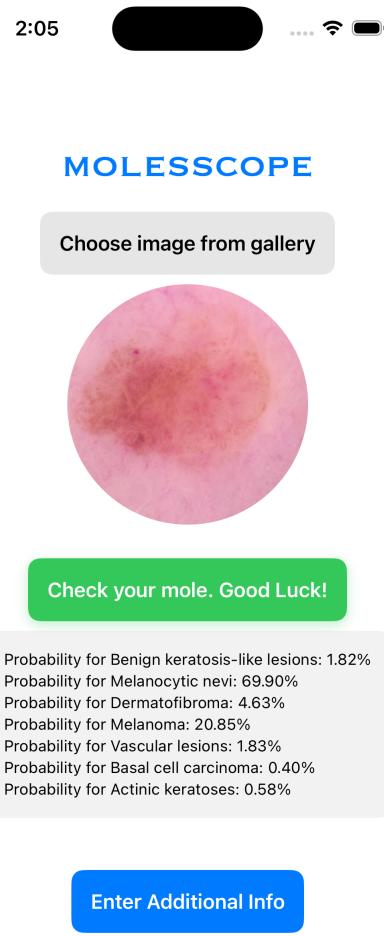
## 5.2. Implementacija

U ovom poglavlju opisuje se implementacija mobilne aplikacije za detekciju melanoma na iOS platformi. Aplikacija je razvijena koristeći SwiftUI i CoreML tehnologije. Aplikacija omogućava korisnicima učitavanje slike kožne lezije, klasifikaciju slike pomoću unaprijed treniranog modela strojnog učenja te prikaz rezultata zajedno s dodatnim informacijama o riziku temeljenom na osobnim karakteristikama korisnika.

### 5.2.1 Glavne komponente aplikacije

Aplikacija se sastoji od dvije glavne komponente: glavnog prikaza (`ContentView`) i prikaza za unos dodatnih informacija (`StatsView`).

### 5.2.2 ContentView



**SL. 5.13:** *ContentView, snimljeno iz Xcode Simulatora*

`ContentView` je glavna točka ulaska aplikacije, gdje korisnik može odabrat sliku iz galerije te pokrenuti klasifikaciju slike. Ova komponenta koristi `PhotosPicker` za odabir slike i prikaz njezine minijature u sučelju aplikacije. Nakon odabira slike, korisnik može pritisnuti gumb za klasifikaciju, što pokreće funkciju `classifyImage()`. Klasifikacija se provodi pomoću CoreML

modela koji je prethodno treniran za prepoznavanje različitih tipova lezija kože, uključujući melanom. Model se učitava putem funkcije `createImageClassifier()`. Nakon što se slika klasificira, rezultati se prikazuju korisniku na ekranu.

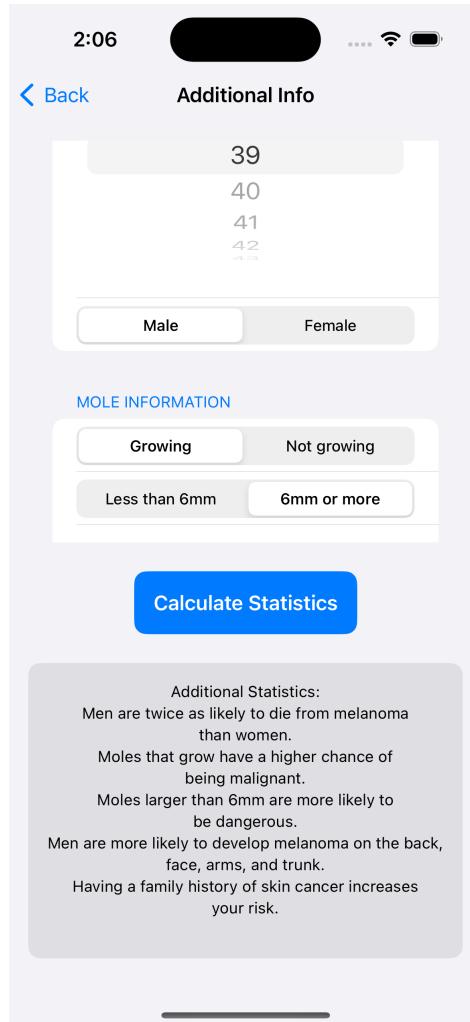
**Primjer koda 10:** *Klasifikacija slike i prikaz rezultata*

```

1 func classifyImage() {
2     guard let model = createImageClassifier() else {
3         print("Failed_to_load_CoreML_model")
4         return
5     }
6
7     Task {
8         if let data = try? await avatarItem?.loadTransferable(type: Data.self),
9             let uiImage = UIImage(data: data),
10            let buffer = uiImage.resize(to: CGSize(width: 50, height: 75))?
11                ↪ toCVPixelBuffer() {
12         if let multiArray = try? MLMultiArray(shape: [1, 37500], dataType: .
13             ↪ float32) {
14             fill(multiArray: multiArray, withPixelBuffer: buffer)
15
16         let modelInput = ModelMolesInput(dense_input: multiArray)
17
18         do {
19             let prediction = try model.prediction(from: modelInput)
20
21             if let outputValue = prediction.featureValue(for: "Identity")?
22                 ↪ multiArrayValue {
23                 print("Prediction_values_for_the_image:")
24                 for i in 0..

```

### 5.2.3 StatsView



**SL. 5.14:** *StatsView, snimljeno iz Xcode Simulatora*

StatsView omogućava korisnicima unos dodatnih informacija poput dobi, spola, boje očiju, boje kose, veličine madeža, njegove lokacije i povijesti melanoma u obitelji. Na temelju ovih informacija, aplikacija generira dodatne statistike o riziku korištenjem funkcije `calculateAdditionalStats()`. Ove statistike pomažu korisnicima da bolje razumiju svoje osobne faktore rizika u vezi s melanomom.

#### Primjer koda 11: Generiranje dodatnih statistika o riziku

```
1 func calculateAdditionalStats() {  
2     var stats = "Additional_Statistics:\n"  
3     if gender == "Male" {  
4         stats += "Men_are_twice_as_likely_to_die_from_melanoma_than_women.\n"  
5     }  
6     if hairColor == "Blonde" {  
7         stats += "People_with_blonde_or_light_hair_also_have_an_increased_risk_"  
8             → compared_to_people_with_darker_hair.\n"  
9     }  
10    if hairColor == "Red" {
```

```

10     stats += "People_with_red_hair_have_a_significantly_higher_risk_of_melanoma.
11         ↪ This_is_linked_to_genetic_variations_that_affect_melanin_production.\n
12         ↪ n"
13     }
14     if eyeColor == "Blue" {
15         stats += "People_with_blue_eyes_have_a_higher_risk_of_developing_skin_
16             ↪ cancer..Less_melanin_in_the_iris_may_mean_less_natural_protection_
17             ↪ against_UV_radiation.\n"
18     }
19     if eyeColor == "Green" {
20         stats += "People_with_green_eyes_have_a_higher_risk_of_developing_skin_
21             ↪ cancer..Less_melanin_in_the_iris_may_mean_less_natural_protection_
22             ↪ against_UV_radiation.\n"
23     }
24     if eyeColor == "Gray" {
25         stats += "People_with_gray_eyes_have_a_higher_risk_of_developing_skin_
26             ↪ cancer..Less_melanin_in_the_iris_may_mean_less_natural_protection_
27             ↪ against_UV_radiation.\n"
28     }
29     if moleGrowing == "Growing" {
30         stats += "Moles_that_grow_have_a_higher_chance_of_being_malignant.\n"
31     }
32     if moleSize == "6mm_or_more" {
33         stats += "Moles_larger_than_6mm_are_more_likely_to_be_dangerous.\n"
34     }
35     if age > 50 {
36         stats += "Older_individuals_have_a_higher_risk_of_skin_cancer.\n"
37     }
38     if (gender == "Female" && (moleLocation == "Legs" || moleLocation == "Back"
39         ↪ || moleLocation == "Face" || moleLocation == "Toes" || moleLocation ==
40         ↪ "Feet")) {
41         stats += "Women_often_develop_melanoma_on_the_legs,_back,_face,_toes,_and_
42             ↪ _feet.\n"
43     }
44     if (gender == "Male" && (moleLocation == "Back" || moleLocation == "Face" ||
45         ↪ moleLocation == "Arms" || moleLocation == "Trunk" || moleLocation ==
46         ↪ "Feet")) {
47         stats += "Men_are_more_likely_to_develop_melanoma_on_the_back,_face,_
48             ↪ arms,_and_trunk.\n"
49     }
50     if familyHistory == "Yes" {
51         stats += "Having_a_family_history_of_skin_cancer_increases_your_risk.\n"
52     }
53     additionalStats = stats
54 }
```

#### 5.2.4 Integracija CoreML modela

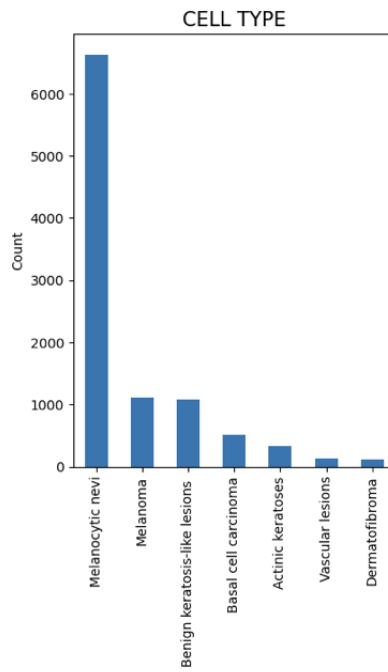
CoreML model, koji je treniran za prepoznavanje različitih tipova lezija kože, integriran je u aplikaciju. Funkcija `createImageClassifier()` inicijalizira model i postavlja konfiguraciju za izvršenje na CPU. Model prihvata ulazne podatke u obliku `MLMultiArray` strukture, koja se generira iz slike korisnika. Klasifikacijski model koristi unaprijed trenirane težine za različite kategorije lezija, a nakon predikcije, rezultati se formatiraju u čitljiv oblik za prikaz korisniku.

## 6. REZULTATI

Mobilna aplikacija *moleSScope* koja predstavlja krajnji proizvod ovog projekta, omogućuje korisnicima klasifikaciju slike kožne lezije odabrane iz galerije mobilnog uređaja. Nakon toga, slika se šalje treniranom modelu koji provodi analizu i klasifikaciju slike u jednu od sedam kategorija lezija.

Model za detekciju kožnih lezija evaluiran je korištenjem standardnih metrika kao što su preciznost, osjetljivost i specifičnost, a ciljevi evaluacije bili su provjeriti učinkovitost modela na testnom skupu podataka. Skup podataka korišten za treniranje i testiranje modela podijeljen je u omjeru 80:20, te je dodatno testni skup podijeljen na validacijski i testni skup u omjeru 90:10, kako bi se osigurala bolja procjena performansi modela.

Model je na testnom skupu postigao točnost od 69%, što je zadovoljavajući rezultat, ali je primijećeno da su performanse modela različite ovisno o klasama. Tako je model pokazao visoku točnost kod klase melanocitnih nevusa (klasa označena kao "nv") s preciznošću od 51%, ali i za melanom (klasa označena kao "mel") model je imao preciznost od 67%. Naročito je zanimljivo da je osjetljivost, koja mjeri koliko dobro model prepoznaje pozitivne slučajeve unutar određene klase, bila relativno visoka za melanom (70%) i vaskularne lezije (95%), no za dermatofibrome model nije bio uspješan, s osjetljivosti od svega desetak posto. To nam daje do znanja da model ima poteškoća s prepoznavanjem određenih, rjeđe zastupljenih klasa. Osim osjetljivosti, važna metrika je specifičnost, koja pokazuje koliko je model dobar u prepoznavanju negativnih slučajeva, odnosno koliko često model ispravno odbacuje slučajeve koji ne pripadaju određenoj klasi. Model je postigao visoku specifičnost od 99% za većinu klasa, što znači da vrlo dobro prepoznaje slike koje ne sadrže promatrane lezije. Razdioba podataka u korištenom



SL. 6.15: Prikaz skupa podataka (tip), snimljeno iz Jupyter Notebooka

skupu nije ravnomjerna, što može negativno utjecati na performanse modela. Naime, većina slika pripada klasama melanocitnih nevusa i melanoma, dok su dermatofibromi i vaskularne lezije slabo zastupljeni. To objašnjava zašto model ima bolje rezultate u prepoznavanju češćih lezija, dok lošije klasificira rjeđe klase kožnih lezija. Kada bi se skup podataka nadopunio tako da svih klasa ima podjednak broj, performanse modela bi bile znatno bolje. Slika 6.15 prikazuje

neravnomjernost u broju primjeraka pojedine klase u skupu podataka.

Usporedbom s drugim znanstvenim radovima kao što je rad Naqvi i suradnika [32], u kojem su korišteni složeniji modeli DenseNet[33] i NASNet[34], vidljivo je da model istreniran za svrhu ovog diplomskog rada zaostaje u performansama. Modeli iz literature često postižu točnost veću od 95%, s F1 rezultatima iznad 0.95, dok model istreniran za svrhu ovog diplomskog postiže F1 rezultat u rasponu od 0.24 do 0.92, ovisno o klasi. Jedan od razloga za ove razlike može biti korištenje jednostavnije arhitekture konvolucijske neuronske mreže modela, ali i ograničenost podataka na kojima je model treniran. Spomenuti model iz literature koristi naprednije arhitekture koje bolje prepoznaju detalje u slikama te su trenirani na većim i raznovrsnijim skupovima podataka, što rezultira boljim performansama.

Na temelju dobivenih rezultata može se primijetiti da model pokazuje zadovoljavajuću razinu uspješnosti u detekciji melanoma, no postoji značajan prostor za daljnje poboljšanje. Da bi se poboljšale performanse modela, preporučuje se razmotriti nekoliko ključnih činjenica. Prije svega, korištenje većih i bolje balansiranih skupova podataka može značajno poboljšati performanse modela, budući da treniranje na ograničenom i neuravnoteženom skupu podataka gotovo uvijek rezultira lošijim performansama naučenog modela. Osim toga, primjena naprednijih tehnika obrade slike kao što je segmentacija, te primjena složenijih arhitektura dubokih neuronskih mreža, kao što je DenseNet, dodatno će povećati točnost, osjetljivost i specifičnost modela. Dodatno, evaluacija modela na stvarnim kliničkim slikama iz svakodnevne prakse pružila bi vrijedan uvid u njegovu stvarnu primjenjivost u medicinskom okruženju te omogućila bolje razumijevanje njegovih prednosti i nedostataka u stvarnim uvjetima. Ovakvi koraci mogli bi dovesti do značajnog povećanja dijagnostičke vrijednosti modela u budućim istraživanjima i kliničkoj primjeni.

## **7. ZAKLJUČAK**

Razvoj metode za detekciju melanoma na koži pomoću strojnog učenja predstavlja značajan korak naprijed u primjeni modernih tehnologija u medicinskoj dijagnostici. U ovom diplomskom radu uspješno je implementiran model koji koristi konvolucijske neuronske mreže za klasifikaciju slika kožnih lezija, a rezultati pokazuju zadovoljavajuću točnost od 69% na testnom skupu podataka.

Iako postoji prostor za poboljšanje, posebno u pogledu povećanja točnosti modela i optimizacije algoritama, rezultati pokazuju da aplikacija može poslužiti kao vrijedan alat za rano otkrivanje melanoma. Integracija funkcionalnosti koja pruža dodatne personalizirane informacije na temelju korisnikovih osobnih podataka dodatno povećava korisnost aplikacije, omogućujući bolju procjenu rizika za svakog pojedinog korisnika.

Mobilna aplikacija razvijena u ovom radu pokazala je da može pružiti korisnicima intuitivan i učinkovit način za praćenje zdravlja njihove kože. Unatoč trenutnim ograničenjima, aplikacija ima potencijal za daljnji razvoj i primjenu u svakodnevnom životu.

Daljnja optimizacija aplikacije i njezina prilagodba korisničkim potrebama mogla bi je učiniti još učinkovitijim alatom za borbu protiv melanoma i drugih kožnih bolesti.

Ovaj rad predstavlja ideju o jednostavnom samodijagnosticiranju pojedinaca kako bi se smanjila smrtnost pacijenata, kako bi rezultati aplikacije pomogli u odluci dermatologa te kako bi se povećala svijest o važnosti prevencije i rane detekcije raka kože.

Važno je naglasiti da cilj ovog rada nije zamijeniti ulogu dermatologa u dijagnostici, već im pružiti dodatni alat koji može pomoći u ranom otkrivanju melanoma. Konačna dijagnoza uvijek će biti u rukama stručnjaka, a ovakvi alati mogu poslužiti kao podrška u njihovom radu, omogućujući bržu i efikasniju procjenu sumnjičivih lezija.

## LITERATURA

- [1] F. Liu et al. Skin cancer dataset. <https://dataVERSE.harvard.edu/dataset.xhtml?persistentId=doi:10.7910/DVN/DBW86T>, 2020. Pristup: 26.08.2024.
- [2] Aleksandra Basta-Juzbašić and suradnici. *Dermatovenerologija*. Medicinska naklada, 2014.
- [3] Poliklinika Eljuga. Uklanjanje madeža - estetski zahvati na tijelu. <https://poliklinika-eljuga.hr/estetska-kirurgija-tijela/zagreb/uklanjanje-madeza>, 2024. Pristup: 26.08.2024.
- [4] Msd priručnik za liječnike. <https://hemed.hr/Default.aspx?sid=11527>, 2018. Pristup: 7.8.2024.
- [5] Ivan Damjanov and Jukić. *Patologija*. Medicinska naklada, 2011.
- [6] Balakrishnan Nirmal. *Dermatoscopy: Physics and principles*. Indian Journal of Dermopathology and Diagnostic Dermatology 4.2, 2017.
- [7] Marko Dabović and Igor Tartalja. *Duboke konvolucijske neuronske mreže – koncepti i aktuelna istraživanja*. Konferencije za elektroniku, telekomunikacije, računarstvo, automatiku i nuklearnu tehniku, 2017.
- [8] GeeksforGeeks. Introduction to convolutional neural networks. <https://www.geeksforgeeks.org/introduction-convolution-neural-network/>, 2024. Pristup: 26.08.2024.
- [9] ResearchGate. Relu activation function. [https://www.researchgate.net/figure/ReLU-activation-function\\_fig3\\_319235847](https://www.researchgate.net/figure/ReLU-activation-function_fig3_319235847), 2017. Pristup: 26.08.2024.
- [10] Europska akademija za certifikaciju informacijskih tehnologija. <https://hr.eitca.org/artificial-intelligence/eitc-ai-adl-advanced-deep-learning/neural-networks/neural-networks-foundations/examination-review-neural-networks-foundations/what-are-the-key-differences-between-activation-functions-such-as-sigmoid-tanh-and-relu-and-how-do-they-impact-the-performance-and-training-of-neural-networks/>, 2024. Pristup: 20.8.2024.
- [11] ResearchGate. An example of the relu activation function. [https://www.researchgate.net/figure/An-example-of-the-ReLU-activation-function\\_fig4\\_374113332](https://www.researchgate.net/figure/An-example-of-the-ReLU-activation-function_fig4_374113332), 2023. Pristup: 26.08.2024.
- [12] Keras. Adam optimizer. <https://keras.io/api/optimizers/adam/>, 2024. Pristup: 26.08.2024.
- [13] John Duchi, Elad Hazan, and Yoram Singer. Adaptive subgradient methods for online learning and stochastic optimization. In *Proceedings of the 14th International Conference on Artificial Intelligence and Statistics (AISTATS)*, pages 212–223, 2011.
- [14] Geoffrey Hinton. Lecture 6e rmsprop: Divide the gradient by a running average of its recent magnitude. [http://www.cs.toronto.edu/~tijmen/csc321/slides/lecture\\_slides\\_lec6.pdf](http://www.cs.toronto.edu/~tijmen/csc321/slides/lecture_slides_lec6.pdf), 2012. Pristup: 26.08.2024.
- [15] Diederik P. Kingma and Jimmy Ba. Adam: A method for stochastic optimization. *CoRR*, 2014. Pristup: 20.8.2024.

- [16] Martín Abadi, Ashish Agarwal, Paul Barham, Eugene Brevdo, Zhifeng Chen, Craig Citro, Greg S. Corrado, Andy Davis, Jeffrey Dean, Matthieu Devin, Sanjay Ghemawat, Ian Goodfellow, Andrew Harp, Geoffrey Irving, Michael Isard, Yangqing Jia, Rafal Jozefowicz, Lukasz Kaiser, Manjunath Kudlur, Josh Levenberg, Dandelion Mané, Rajat Monga, Sherry Moore, Derek Murray, Chris Olah, Mike Schuster, Jonathon Shlens, Benoit Steiner, Ilya Sutskever, Kunal Talwar, Paul Tucker, Vincent Vanhoucke, Vijay Vasudevan, Fernanda Viégas, Oriol Vinyals, Pete Warden, Martin Wattenberg, Martin Wicke, Yuan Yu, and Xiaoqiang Zheng. Tensorflow: Large-scale machine learning on heterogeneous systems. <https://www.tensorflow.org/>, 2015.
- [17] François Chollet. Keras. <https://keras.io>, 2015.
- [18] Google Developers. Machine learning crash course. <https://developers.google.com/machine-learning/crash-course>, 2024. Pristup: 26.08.2024.
- [19] AiMind. Custom model building in tensorflow/keras. <https://pub.aimind.so/custom-model-building-in-tensorflow-keras-36bf04da3f3f>, 2024. Pristup: 26.08.2024.
- [20] Apple dokumentacija za xcode programsko sučelje. <https://developer.apple.com/documentation/createml>. Pristup: 20.7.2024.
- [21] Andrew J. Wagner. *Naučite Swift*. Dobar Plan Publishing Company, 2016.
- [22] Apple dokumentacija za xcode programsko sučelje. <https://developer.apple.com/xcode/>. Pristup: 20.7.2024.
- [23] Apple dokumentacija za swift programski jezik. <https://developer.apple.com/swift/>. Pristup: 20.7.2024.
- [24] Teresa Kränke, Katharina Tripolt-Droschl, Lukas Röd, Rainer Hofmann-Wellenhof, Michael Koppitz, and Michael Tripolt. Novi ai-algoritmi na pametnim telefonima za otkrivanje raka kože u kliničkim uvjetima validacijska studija. *PLoS One*, 18(2), 2023. Pristup: 20.8.2024.
- [25] Andre Esteva, Brett Kuprel, Roberto A Novoa, Justin Ko, Susan M Swetter, Helen M Blau, and Sebastian Thrun. Dermatologist-level classification of skin cancer with deep neural networks. *Nature*, 542:115–118, 2017.
- [26] AA Teodoro et al. A skin cancer classification approach using gan and roi-based attention mechanism. *Journal of Signal Processing Systems*, pages 1–14, 2022.
- [27] Holger A Haenssle, Christoph Fink, Ruth Schneiderbauer, et al. Man against machine: diagnostic performance of a deep learning convolutional neural network for dermoscopic melanoma recognition in comparison to 58 dermatologists. *Annals of Oncology*, pages 1836–1842, 2020.
- [28] L Marchetti, J Kvedar, M Mikhail, et al. Effectiveness of smartphone applications for triaging skin lesions: a systematic review. *BMJ*, page m127, 2020.
- [29] Ieva Nagy, Patricia Fisch, Mateusz Lechowicz, Paolo Balboni, and Yannis Michaloudis. A sustainable antiviral face mask: From post-consumer recycled pet and cotton fibers and active chemicals for covid-19 prevention. *Materials Today Sustainability*, 2020. Pristup: 26.08.2024.

- [30] M. Mahdavi. Skin cancer dataset. <https://www.kaggle.com/datasets/mahdavi1202/skin-cancer>, 2024. Pristup: 26.08.2024.
- [31] The WebAppMarket. Scanoma app review. <https://thewebappmarket.com/scanoma-app-review/>, 2024. Pristup: 26.08.2024.
- [32] Maryam Naqvi, Syed Qasim Gilani, Tehreem Syed, Oge Marques, and Hee-Cheol Kim. Skin cancer detection using deep learning—a review. *Diagnostics*, 13(11):1911, 2023.
- [33] PyTorch. Densenet. [https://pytorch.org/hub/pytorch\\_vision\\_densenet/](https://pytorch.org/hub/pytorch_vision_densenet/), 2024. Pristup: 26.08.2024.
- [34] Keras. Nasnet. <https://keras.io/api/applications/nasnet/>, 2024. Pristup: 26.08.2024.

## **SAŽETAK**

Uvođenje naprednih tehnologija u medicinu značajno je unaprijedilo dijagnostiku i lijeчење brojnih bolesti, uključujući melanom, najopasniji oblik raka kože. Razvoj metoda strojnog učenja omogućuje precizniju analizu dermatoloških slika, što doprinosi ranijem otkrivanju i uspješnijem lijeчењu melanoma.

U ovom diplomskom radu istražuje se primjena strojnog učenja u detekciji melanoma korištenjem mobilnih uređaja. Prednosti mobilnih uređaja je u njihovoј dostupnosti i praktičnosti, čime se omogućava šira upotreba dijagnostičkih alata u svakodnevnom životu. Korištenjem suvremenih algoritama strojnog učenja, mobilne aplikacije mogu postati pouzdani asistenti dermatologa u prepoznavanju sumnjivih lezija kože. Cilj ovog rada je prikazati mogućnosti i ograničenja ovakvih sustava te ponuditi rješenja za njihovo poboljšanje i širu primjenu u medicinskoj praksi.

**Ključne riječi:** melanom, lezije, strojno učenje.

## ABSTRACT

The introduction of advanced technologies in medicine has significantly improved the diagnosis and treatment of numerous diseases, including melanoma, the most dangerous form of skin cancer. The development of machine learning methods enables more precise analysis of dermatological images, which contributes to earlier detection and more successful treatment of melanoma.

This thesis examines the application of machine learning in melanoma detection using mobile devices. The advantages of mobile devices lie in their availability and practicality, which enables the wider use of diagnostic tools in everyday life. By using modern machine learning algorithms, mobile applications can become reliable assistants to dermatologists in identifying suspicious skin lesions. The aim of this paper is to show the possibilities and limitations of such systems and to offer solutions for their improvement and wider application in medical practice.

**Keywords:** melanom, lesions, machine learning.

## ŽIVOTOPIS

Rođen sam 8. listopada 1999. godine u Požegi. Osnovnu školu fra Kaje Adžića u Pleternici pohađao sam u razdoblju od 2006. godine do 2014. godine. Tijekom tog razdoblja redovno sam sudjelovao na natjecanjima iz matematike što je rezultiralo upisivanjem prirodoslovno-matematičke gimnazije u Požegi, a istu sam završio 2018. godine. Nakon završene srednje škole pohađao sam Wimbledon School of English 2018. godine u Londonu te nakon toga odlučujem upisati Preddiplomski studij Matematike i računarstva na Odjelu za matematiku Sveučilišta J.J. Strossmayera u Osijeku. Akademski naziv sveučilišnog prvostupnika matematike i računarstva stječem 2022. godine završnim radom pod nazivom "Sučelje za implementaciju stvarnih dronova u simulatoru" uz mentorstvo doc. dr. sc. Domagoja Ševerdija. Potom sam upisao Diplomski studij računarstva, smjer Informacijske i podatkovne znanosti na Fakultetu elektrotehnike, računarstva i informacijskih tehnologija Sveučilišta J.J. Strossmayera u Osijeku. Tijekom diplomskog studija bio sam aktivna član studentske udruge IEEE Student Branch Osijek. Svoje radno iskustvo počeo sam graditi 2021. godine na stručnoj praksi u firmi Orqa d.o.o. u Osijeku, gdje sam nakon te prakse ostao raditi u ulozi Software Programmera. 2022. godine pohađao sam iOS Academy u organizaciji IEEE-a i FERIT-a. Nakon toga sam 2023. godine radio u Visage Technologies d.o.o. u Zagrebu kao Software Tester, te kao pomoćnik u implementaciji u firmi Proprium d.o.o. iste godine u Osijeku. Potom sam obavio stručnu praksu u firmi Atos CVC d.o.o. 2024. godine te sam u firmi Soldered Electronics d.o.o. iste godine radio kao studentski zaposlenik. Pohađao sam ljetnu Enea Academy 2024. godine te trenutno radim u Enea Software d.o.o. u Osijeku na mjestu Software Engineera.

## POPIS SLIKA

Slika 1 : ABCD pregled, dostupno na :

(<https://poliklinika-eljuga.hr/estetska-kirurgija-tijela/zagreb/uklanjanje-madeza>) - stranica 3

Slika 2 : Schema Konvolucijskih Neuronskih Mreža, dostupno na :

(<https://www.geeksforgeeks.org/introduction-convolution-neural-network>) - stranica 8

Slika 3 : Aktivacijska funkcija ReLu, dostupno na :

([https://www.researchgate.net/figure/ReLU-activation-function\\_fig3\\_319235847](https://www.researchgate.net/figure/ReLU-activation-function_fig3_319235847)) - stranica 9

Slika 4 : Djelovanje aplikacijske ReLu funkcije na sliku koja je zapisana u matričnom obliku, dostupno na :

([https://www.researchgate.net/figure/An-example-of-the-ReLU-activation-function\\_fig4\\_374113332](https://www.researchgate.net/figure/An-example-of-the-ReLU-activation-function_fig4_374113332)) - stranica 10

Slika 5 : Hijerarhija TensorFlow-a, dostupno na

(<https://developers.google.com/machine-learning/crash-course/first-steps-with-tensorflow/toolkit>) - stranica 13

Slika 6 : Sequential, dostupno na

(<https://pub.aimind.so/custom-model-building-in-tensorflow-keras-36bf04da3f3f>) - stranica 13

Slika 7 : Prikaz prikupljanja uzoraka za PAD-UFES-20 skup podataka, dostupno na

(<https://www.sciencedirect.com/science/article/pii/S235234092031115X>) - stranica 19

Slika 8 : Scanoma mobilna aplikacija za detekciju melanoma, dostupno na

(<https://thewebappmarket.com/scanoma-app-review/>) - stranica 21

Slika 9 : Prikaz skupa podataka (pet primjera za svaki tip), snimljeno iz Jupyter Notebooka - stranica 23

Slika 10 : Prikaz skupa podataka (dob, spol, lokacija, tip), snimljeno iz Jupyter Notebooka - stranica 24

Slika 11 : Prikaz skupa podataka (odnos lokacija i spol), snimljeno iz Jupyter Notebooka - stranica 24

Slika 12 : Prikaz skupa podataka (dob i spol s tipom), snimljeno iz Jupyter Notebooka - stranica 25

Slika 13 : ContentView, uslikano iz Xcode Simulatora - stranica 26

Slika 14 : StatsView, uslikano iz Xcode Simulatora - stranica 28

Slika 15 : Prikaz skupa podataka (tip), snimljeno iz Jupyter Notebooka - stranica 31