



Aplikasi *Mobile* Deteksi Dini Kanker Kulit Berdasarkan *Image Processing*

Fina Royana¹, Puput Yuniar Maulida, Rully Nurul Hasanah³, Sondari Setia Rahayu^{*4}, Rasim⁵

^{1,2,3,4,5} Department of Computer Science, Universitas Pendidikan Indonesia, Bandung, 40154, Indonesia

* Correspondence: E-mail: sondari@upi.edu

ABSTRACTS

Skin cancer is one type of cancer that can cause death for many people. So an application is needed to detect skin cancer early easily so that the cancer can be treated more quickly. In addition, consultation with a dermatologist has a better prognosis (Avilés-Izquierdo et. al., 2016). So, we built an early detection application for skin cancer equipped with a consultation feature. This app helps diagnose skin cancer before it develops into a life-threatening condition and is essential for maintaining lifestyle, future health, and aesthetics. And, through the online doctor consultations we have, getting a diagnosis, prescription, treatment, not spending time traveling to the doctor and waiting in line, is effective. It uses three management techniques such as machine learning to create data pipelines, build models, and convert models to TensorFlow lite. Android to implement tensorflow lite model and create apps. It has a real-time connection using firebase. Cloud to create a simple database for physician services and diagnosis in firebase.

ARTICLE INFO

Article History:

Received 25 Jun 2021

Revised 30 Des 2021

Accepted 31 Des 2021

Available online 31 Des 2022

Keyword:

Firestore,
Image Processing,
Mobile Application,
Skin Detection,
Transfer Learning,

ABSTRAK

Kanker kulit merupakan salah satu jenis kanker yang dapat menyebabkan kematian bagi banyak orang. Sehingga diperlukan sebuah aplikasi untuk mendeteksi kanker kulit secara dini dengan mudah sehingga kanker tersebut dapat ditangani dengan lebih cepat. Selain itu, konsultasi dengan dokter kulit memiliki prognosis yang lebih baik (Avilés-Izquierdo et. al., 2016). Maka, Kami membangun aplikasi deteksi dini kanker kulit dilengkapi dengan fitur konsultasi. Aplikasi ini membantu mendiagnosis kanker kulit sebelum berkembang menjadi kondisi yang mengancam jiwa dan sangat penting untuk mempertahankan gaya hidup, kesehatan masa depan, dan estetika. Serta, melalui konsultasi dokter online yang kami miliki, mendapatkan diagnosis, resep, perawatan, tidak menghabiskan waktu bepergian ke dokter dan menunggu dalam antrian, merupakan hal yang efektif. Dengan menggunakan tiga teknik pengelolaan seperti *machine learning* untuk membuat *pipeline* data, membangun model, dan mengonversi model ke TensorFlow lite. Android untuk menerapkan model TensorFlow lite dan membuat aplikasi. Memiliki koneksi *real-time* menggunakan firebase. Cloud untuk membuat *database* sederhana untuk layanan dokter dan diagnosis di firebase.

Keyword:

Firestore,
Pengolahan citra,
Aplikasi Seluler,
Deteksi Kulit,
Transfer Pembelajaran,

1. INTRODUCTION

Pasien dengan melanoma yang terdeteksi oleh dokter kulit memiliki prognosis yang lebih baik daripada pasien dengan melanoma yang terdeteksi sendiri. (Avilés-Izquierdo et. al., 2016). Kurangnya kemanjuran pemeriksaan diri pada pasien lanjut usia, faktor terkait pasien dari keterlambatan diagnosis, lokasi di area tubuh yang tidak mudah terlihat, tidak adanya tanda-tanda peringatan ABCDE klasik (seperti pada melanoma amelanotik), dan hambatan praktisi perawatan primer untuk pemeriksaan kulit secara teratur adalah semua faktor yang dapat menjelaskan mengapa melanoma tebal tidak menurun.

Insiden kanker kulit non-melanoma dan melanoma telah meningkat selama beberapa dekade terakhir. Saat ini, antara 2 dan 3 juta kanker kulit non-melanoma dan 132.000 kanker kulit melanoma terjadi secara global setiap tahun. Satu dari setiap tiga kanker yang didiagnosis adalah kanker kulit dan, menurut Statistik Yayasan Kanker Kulit, satu dari setiap lima orang Amerika akan mengembangkan kanker kulit dalam hidup mereka. Ketika kadar ozon menipis, atmosfer kehilangan semakin banyak fungsi filter pelindungnya dan lebih banyak radiasi UV matahari mencapai permukaan Bumi. Diperkirakan bahwa penurunan kadar ozon 10 persen akan menghasilkan tambahan 300.000 kasus kanker kulit non-melanoma dan 4.500 melanoma. Insiden global melanoma terus meningkat - namun, faktor utama yang cenderung terhadap perkembangan melanoma tampaknya terhubung dengan paparan rekreasi matahari dan sejarah sengatan matahari. Faktor-faktor ini terletak pada tanggung jawab masing-masing individu sendiri.

Tidak seperti bentuk kanker lainnya, pelaporan diagnosis kanker kulit tidak diperlukan oleh sebagian besar registri kanker (CCA, 2018). Terlepas dari itu, Organisasi Kesehatan Dunia (WHO) memperkirakan bahwa satu dari setiap tiga kasus di mana seseorang didiagnosis menderita kanker adalah kanker kulit (WHO, 2017). Kanker kulit adalah salah satu jenis kanker yang paling umum di

seluruh dunia. Selama beberapa tahun terakhir, pendekatan yang berbeda telah diusulkan untuk menangani deteksi kanker kulit otomatis, seperti UMSkinCheck, Miiskin, SkinVision, dll. Tapi, ada kurangnya akurasi, misalnya SkinVision memiliki akurasi interval 63% hingga 92% (Freeman et. al., 2020), dan deteksi kanker kulit berdasarkan arsitektur jaringan saraf konvolusional yang mendalam mencapai skor akurasi keseluruhan 88% (Saeed, 2021).

Kanker kulit adalah salah satu jenis kanker yang dapat menyebabkan kematian bagi banyak orang. Akibatnya, diperlukan aplikasi untuk mendeteksi kanker kulit sejak dini sehingga dapat diobati sesegera mungkin. Selain itu, konsultasi dokter kulit memiliki prognosis yang lebih baik. Sebagai konsekuensinya, kami mengembangkan aplikasi deteksi kanker kulit awal bekerja sama dengan dokter kulit. Diagnosis dini kanker kulit sebelum tumbuh menjadi kondisi yang mengancam jiwa sangat penting untuk melestarikan gaya hidup, kesehatan masa depan, dan estetika Anda. Selain itu, berkat konsultasi dokter *online*, bagaimanapun, mendapatkan diagnosis, diresepkan dan dirawat untuk masalah Anda tanpa menghabiskan waktu bepergian ke dan dari dokter dan menunggu dalam antrean bisa sama efektifnya.

2. METHODS

2.1 Data augmentation and preprocessing

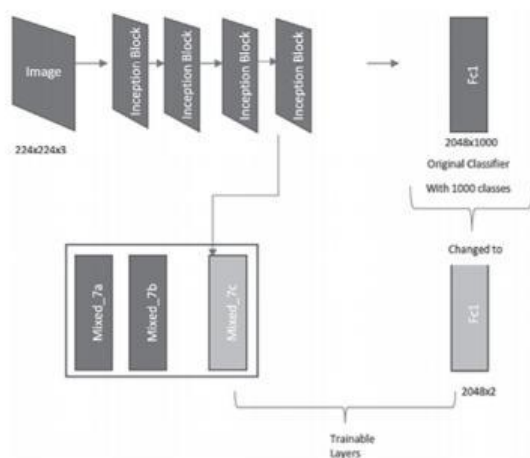
Pra-pemrosesan data citra kulit adalah tugas yang sangat penting di CNN. Terkadang karena ketersediaan dataset yang lebih sedikit atau kecil jaringan menjadi overfitted. Dalam overfitting, CNN berkinerja sangat baik dalam data pelatihan tetapi berkinerja buruk dalam data pengujian.

Untuk mengurangi masalah overfitting, teknik augmentasi data telah diterapkan menggunakan arsitektur CNN yang berbeda yang meningkatkan ukuran dataset dan melakukan transformasi geometrik ke dataset gambar. Karena rotasi karakteristik invarian gambar lesi kulit mikroskopis mereka mudah diidentifikasi dan dianalisis oleh ahli patologi. Itu ahli

patologi memeriksa gambar-gambar ini dari orientasi dan sudut yang berbeda tanpa kehilangan variasi atau metode apa pun diagnosa.

2.2 Inception V3

Inception V3 adalah model CNN canggih yang juga dikenal sebagai GoogleNet yang dilatih lebih dari jutaan gambar dari data ImageNet sumber. Jaringan memiliki kemampuan untuk mengenali gambar yang lebih luas daripada masuk lebih dalam ke jaringan. Kemampuannya untuk melibatkan beberapa konvolusi kecil dengan jenis dan ukuran parameter terbatas daripada konvolusi ukuran filter yang lebih besar dan akhirnya menggabungkan mereka membuatnya berbeda dari yang lain. Melalui pemanfaatan jaringan tersebut, filter yang berbeda dari beragam ukuran digabungkan menjadi filter tunggal baru yang tidak hanya mengurangi ukuran filter konvolusi tetapi juga mengurangi keseluruhan kompleksitas komputasi jaringan dan memungkinkan klasifikasi lesi kanker kulit yang lebih halus. Detail Inception V3 arsitektur diilustrasikan pada Gambar 2.2.



Gambar 2.2 Arsitektur dari Inception V3

2.3 Transfer learning

Biasanya, pelatihan CNN dari awal membutuhkan ukuran data yang besar tetapi terkadang sulit untuk mengumpulkan data yang besar jumlah ukuran data untuk tujuan klasifikasi. Tetapi dalam konteks masalah dunia nyata, terkadang sangat sulit untuk mencocokkan pelatihan dan data pengujian.

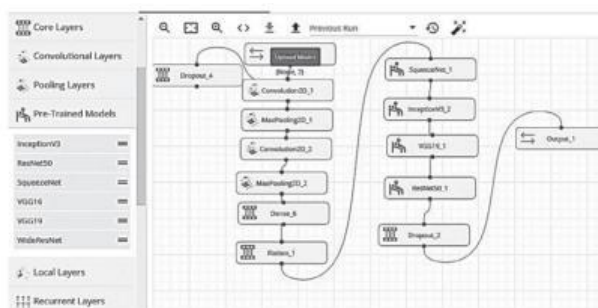
Hal ini menyebabkan pengenalan konsep transfer learning. Ini adalah salah satu mesin canggih metode pembelajaran yang mempelajari pengetahuan yang diperlukan untuk memecahkan masalah dan menggunakan kembali serta menerapkan pengetahuan yang sama untuk memecahkan masalah lain dari setiap domain yang relevan. Pada tugas tertentu, jaringan konteks dilatih menggunakan kumpulan data yang sesuai dan kemudian tugas telah ditransfer ke target tertentu yang dimaksudkan untuk dilatih oleh dataset target.

Transfer Learning melibatkan pemilihan model yang telah dilatih sebelumnya, ukuran masalah, dan kesamaan. Pemilihan model murni relevan dengan target masalah yang terkait dengan masalah atau tugas konteks, jika ukuran kumpulan data target lebih kecil atau mirip dengan kumpulan sumber kemudian mengarah ke overfitting data. Namun, jika ukuran kumpulan data lebih dari itu, model pra-latihan hanya memerlukan penyetulan yang lebih baik terlepas dari melakukan langkah-langkah yaitu, pengembangan model dari awal.

Penyesuaian kerangka kerja yang diusulkan dan pelatihan model dicapai dengan bantuan empat kategori model yang telah dilatih sebelumnya sebagai: dibahas pada bagian sebelumnya. Model-model ini dilatih dari gambar sampel yang diambil dari dataset ImageNet dan yang lebih baru transfer learning diterapkan untuk data lesi kulit. Ini memfasilitasi peningkatan kemampuan generalisasi arsitektur untuk belajar dari dataset lain tanpa persyaratan pelatihan dari awal.

Setelah lapisan konvolusi menggulung sumber data dan kirim ke lapisan penyatuan untuk pengurangan ukuran spasial yang telah terhubung dengan lapisan yang diratakan atau terhubung sepenuhnya untuk mendapatkan output untuk klasifikasi kanker kulit menjadi

lesi kulit ganas atau jinak menggunakan pooling maks atau rata-rata. Itu pembuatan model untuk arsitektur pra-latihan yang berbeda ditunjukkan pada Gambar 2.3, dimana lapisan inti dan padat yang berbeda memiliki telah dibuat.



Gambar 2.3 Pembuatan model menggunakan transfer learning

2.4 Dataset

Untuk mengevaluasi kinerja kerangka yang diusulkan, 7 kategori gambar, diantaranya sebagai berikut

1. Actinic keratosis (Akeic)
2. Basal cell carcinoma (Bcc)
3. Seborrheic keratoses (Bkl)
4. Dermatofibromas(Df)
5. Melanoma (Mel)
6. melanocytic naevus (Nv)
7. Angiomas (Vasc)

Dataset tersebut diambil dari kaggle yang awalnya mencakup lebih dari 10.000 gambar. Namun untuk studi penelitian ini, dengan menerapkan teknik augmentasi gambar diperkecil, diputar, dan dimodelkan yang selanjutnya dikurangi jumlahnya menjadi 1000 dari mana 3800 digunakan untuk melatih arsitektur dan 1200 adalah digunakan untuk menguji model yang dilatih. Semua kelas yaitu Actinic keratosis (Akeic), Basal cell carcinoma (Bcc), Seborrheic keratoses (Bkl), Dermatofibromas(Df), Melanoma (Mel), melanocytic naevus (Nv), Angiomas (Vasc) seperti yang ditunjukkan. Berdasarkan validasi kinerja pendekatan kriteria penghentian dirancang yang digunakan untuk mengontrol

masalah overfitting setelah 700 jumlah epoch atau iterasi

2.5 Firebase

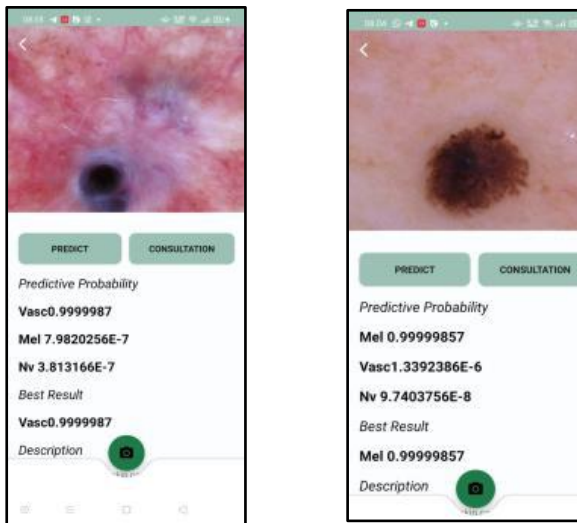
Sebagian besar aplikasi perlu mengetahui identitas pengguna. Dengan mengetahui identitas pengguna, aplikasi dapat menyimpan data pengguna secara aman di cloud dan memberikan pengalaman personal yang sama di setiap perangkat pengguna. Begitu pula pada aplikasi ini, untuk dapat mengakses sistem pada aplikasi ini, pengguna diharuskan membuat sebuah akun terlebih dahulu, dan setelah akun dibuat, maka akan dilakukan otentikasi setiap user dengan Firebase Authentication.

Firebase Authentication bertujuan untuk memudahkan pembangunan sistem autentikasi yang aman, sekaligus meningkatkan pengalaman login dan pengalaman orientasi bagi pengguna akhir. Fungsi ini menyediakan solusi identitas end-to-end, mendukung akun email dan sandi, autentikasi ponsel, Google, Twitter, Facebook, GitHub, dan lain-lain.

Dalam penyimpanan data, kami melakukan penyimpanan di Cloud Firestore. **Cloud Firestore** adalah database NoSQL yang dihosting di cloud dan dapat diakses langsung oleh aplikasi iOS, Android, dan web melalui SDK native. Cloud Firestore menyimpan data yang digunakan secara aktif oleh aplikasi kami, baik itu data identitas pengguna, data foto penyakit, dan juga data identitas dokter, sehingga aplikasi dapat menulis, membaca, mendeteksi, dan melakukan kueri data meskipun perangkat sedang offline. Saat perangkat kembali online, Cloud Firestore akan menyinkronkan semua perubahan lokal kembali ke Cloud Firestore.

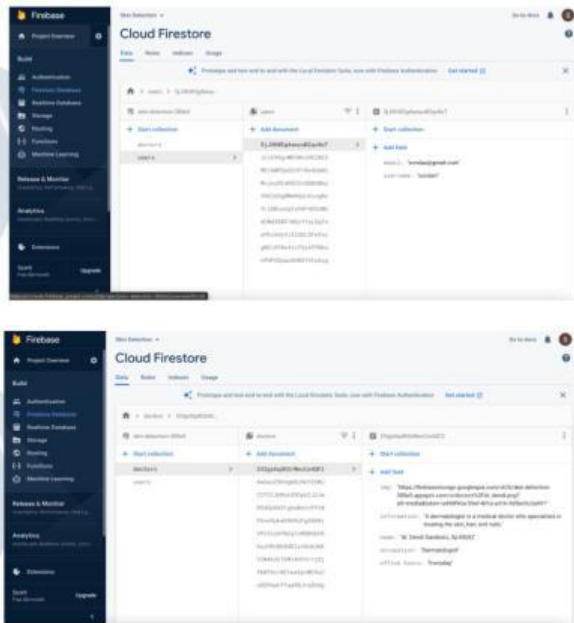
3. RESULTS AND DISCUSSION

3.1. Results Mobile Applications



Result Detection Skin cancer

3.2 Result Cloud Firestore



3.3 Result Machine Learning

1. Preprocessing csv data and split into 7 classes

total data: 10015

	precision	recall	f1-score	support
0	0.53	0.43	0.48	23
1	0.59	0.65	0.62	26
2	0.60	0.55	0.57	66
3	0.56	0.83	0.67	6
4	0.46	0.62	0.52	34
5	0.96	0.95	0.95	663
6	1.00	0.80	0.89	10
accuracy			0.88	828
macro avg	0.67	0.69	0.67	828
weighted avg	0.88	0.88	0.88	828

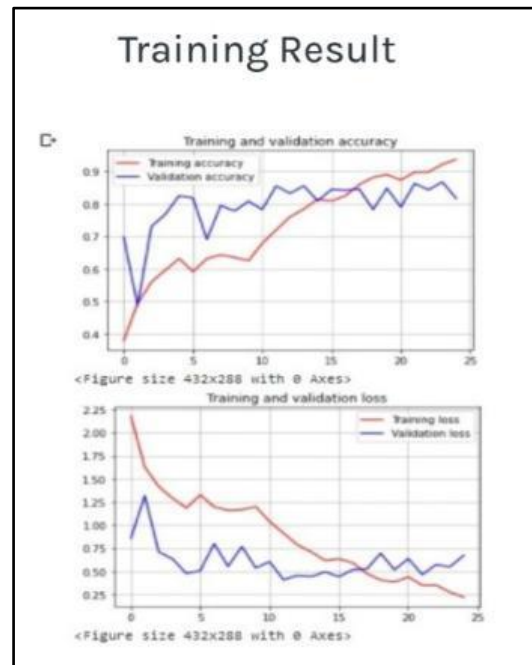
2. Oversampling train data with image augmentation

```
Found 51699 images belonging to 7 classes.
Found 828 images belonging to 7 classes.
```

3. Rescaling on top of InceptionResNet and add Flatten and Dense at bottom layer

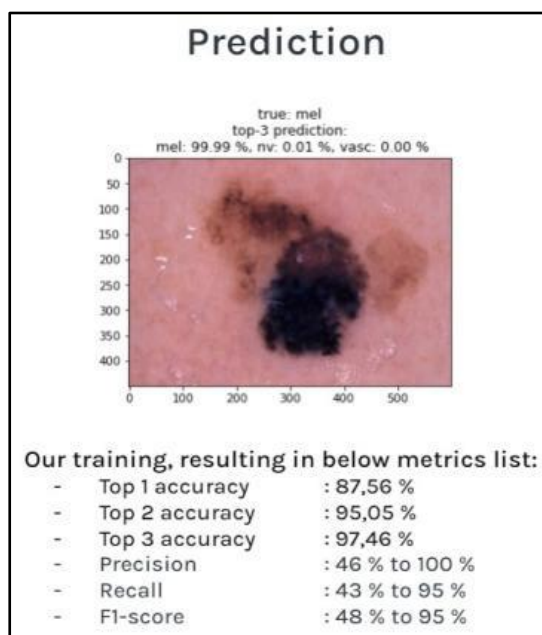
```
Model: "sequential"
Layer (type)                Output Shape                Param #
-----
rescaling_1 (Rescaling)      (None, 150, 150, 3)         0
inception_resnet_v2 (Funcio  (None, 3, 3, 1536)         54336736
flatten (Flatten)            (None, 13824)               0
dense (Dense)                 (None, 7)                   96775
-----
Total params: 54,433,511
Trainable params: 54,372,967
Non-trainable params: 60,544
```

4. Training data



5. Predict list

6. Prediction gambar model machine learning



7. Top 3 Akurasi model

top-1 accuracy:	87.560 %
top-2 accuracy:	95.048 %
top-3 accuracy:	97.464 %

4. CONCLUSION

Perbandingan dengan aplikasi serupa (klasifikasi lesi kulit berdasarkan arsitektur jaringan saraf *convolutional*), aplikasi yang telah penulis buat memiliki 9% akurasi yang lebih baik. Deteksi kanker kulit (klasifikasi lesi kulit berdasarkan arsitektur jaringan saraf *convolutional*) mencapai skor akurasi keseluruhan 88% (Saeed, 2021), sementara aplikasi penulis memiliki akurasi 97%. Ini berarti aplikasi penulis memiliki akurasi sekitar 9% lebih baik dalam *machine learning testing*. Namun, aplikasi ini membutuhkan intervensi dokter ahli untuk mengidentifikasi fitur-fitur yang tersedia. Dalam penelitian ini, untuk mengklasifikasikan dan mengidentifikasi melanoma kanker kulit dengan benar, pendekatan efisien berbasis pembelajaran transfer diusulkan oleh menggunakan model ResNetV2.

5. ACKNOWLEDGEMENTS

Penulis mengucapkan terima kasih banyak kepada seluruh staff Bangkit yang telah memberikan kesempatan dan memfasilitasi penulis untuk dapat merealisasikan ide dan mengembangkan aplikasi ini.

6. REFERENCES

- Adegun, A., & Viriri, S. (2021). Deep learning techniques for skin lesion analysis and melanoma cancer detection: a survey of state-of-the-art. *Artificial Intelligence Review*, 54(2), 811-841.
- Avilés-Izquierdo, J. A., Molina-López, I., Rodríguez-Lomba, E., Marquez-Rodas, I., Suarez-Fernandez, R., & Lazaro-Ochaita, P. (2016). Who detects melanoma? Impact of detection patterns on characteristics and prognosis of patients with melanoma. *Journal of the American Academy of Dermatology*, 75(5), 967-974.
- Dildar, M., Akram, S., Irfan, M., Khan, H. U., Ramzan, M., Mahmood, A. R., ... & Mahnashi, M. H. (2021). Skin Cancer Detection: A Review Using Deep Learning Techniques. *International journal of environmental research and public health*, 18(10), 5479.
- Freeman, K., Dinnes, J., Chuchu, N., Takwoingi, Y., Bayliss, S. E., Matin, R. N., ... & Deeks, J. J. (2020). Algorithm based smartphone apps to assess risk of skin cancer in adults: systematic review of diagnostic accuracy studies. *bmj*, 368.
- Hosny, K. M., Kassem, M. A., & Foad, M. M. (2018, December). Skin cancer classification using deep learning and transfer learning. In *2018 9th Cairo International Biomedical Engineering Conference (CIBEC)* (pp. 90-93). IEEE.

- Khamparia, A., Singh, P. K., Rani, P., Samanta, D., Khanna, A., & Bhushan, B. (2020). An internet of health things-driven deep learning framework for detection and classification of skin cancer using transfer learning. *Transactions on Emerging Telecommunications Technologies*, e3963.
- Pacheco, A. G., & Krohling, R. A. (2020). The impact of patient clinical information on automated skin cancer detection. *Computers in biology and medicine*, 116, 103545.
- Tschandl, P., Rosendahl, C., & Kittler, H. (2018). The HAM10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions. *Scientific data*, 5(1), 1-9.