

# Penerapan Convolutional Neural Network untuk Klasifikasi Kanker Kulit Melanoma pada Dataset Gambar Kulit

Michael Kurniawan Soegeng, Liliana, Agustinus Noertjahyana  
Program Studi Informatika, Fakultas Teknologi Industri, Universitas Kristen Petra  
Jln. Siwalankerto 121 – 131 Surabaya 60236  
Telp. (031)-2983455, Fax. (031)-8417658  
michaelks540@gmail.com, lilian@petra.ac.id, agust@petra.ac.id

## ABSTRAK

Salah satu kanker kulit yang paling berbahaya adalah kanker kulit melanoma. Kanker ini berbahaya karena keganasan dan kecepatan kanker untuk menyebar ke bagian lain dari tubuh dan menyebabkan kematian. Deteksi dini kanker kulit melanoma dapat mengurangi tingkat mortalitas dari kanker kulit melanoma. Oleh karena itu, diperlukan sebuah metode untuk membantu melakukan diagnosa lesi kulit secara otomatis untuk membedakan kanker kulit melanoma dan lesi kulit biasa. Metode yang sudah ada untuk melakukan klasifikasi lesi kulit melanoma masih memiliki limitasi pada kemampuan untuk melakukan klasifikasi. Pada penelitian ini untuk meningkatkan akurasi klasifikasi digunakan model EfficientNet dan ResNet yang telah dilatih dengan *dataset* asli ISIC 2020 dan *dataset* yang telah di proses menggunakan algoritma penghapusan rambut yang kemudian digabungkan dengan metode *ensemble*.

Pada proses klasifikasi, *dataset* ISIC 2020 akan diolah menggunakan algoritma penghapusan rambut. Kemudian model akan dilatih menggunakan *dataset* asli dan *dataset* yang telah diolah. Kemudian, model yang dihasilkan akan digunakan untuk melakukan *ensemble* dimana hasil setiap model akan dirata – rata untuk memberi prediksi gabungan. Kemampuan model akan diuji menggunakan *test dataset* ISIC 2020.

Pengujian yang dilakukan diukur menggunakan metrik akurasi *area under the receiver operating characteristic curve* (ROC AUC). Pengujian dengan melakukan *hair removal* menunjukkan terdapat penurunan akurasi disebabkan setelah penghapusan rambut, model mempelajari lebih banyak fitur dari kulit biasa dibanding fitur lesi kulit. *Ensembling* hasil prediksi dapat meningkatkan kemampuan model untuk melakukan prediksi dengan lebih akurat dengan menggabungkan beberapa model menjadi satu meta-model sehingga mencapai tingkat akurasi yang lebih tinggi dengan akurasi terakhir mencapai 93.108%.

**Kata Kunci:** *Convolutional neural network, transfer learning, Deep learning, skin lesion classification, Hair Removal, Ensemble neural network*

## ABSTRACT

*Melanoma skin cancer is one of the most dangerous skin cancers where the ferocity and speed of metastasis has caused a high mortality rate among afflicted when the cancer is not treated. Early detection of the cancer and prevention by removing the affected skin have been shown to decrease the mortality rate on afflicted patient. Thus, development of a method to help automatically diagnose the cancer and classify between cancer and normal mole or birthmark is needed. Previous methods still show limitations in classifying melanoma skin cancer. This study proposes a classification system using convolutional neural network trained*

*on the original ISIC 2020 dataset and hair removed dataset which is then combined using ensemble.*

*The dataset used is first preprocessed using the hair removal algorithm convolutional neural network using EfficientNet B0 – B7 and ResNet-50-v2 will be trained using ISIC 2020 dataset and ISIC 2020 dataset processed with hair removal algorithm. The model is evaluated using test data from ISIC 2020 dataset on area under the receiver operating characteristic curve (ROC AUC). The model trained will then be combined using ensemble where the result of the model will be averaged to give a combined prediction.*

*The result of the test shows that the model trained is capable to classify melanoma and non-melanoma images. It is also shown that by removing hair from the skin image reduces the accuracy of the model. Using Ensembling on the different models trained into one meta-model also increases the accuracy of the prediction giving a high final accuracy of 93.108%.*

**Keywords:** *Convolutional neural network, transfer learning, Deep learning, skin lesion classification, Hair Removal, Ensemble neural network*

## 1. PENDAHULUAN

Kanker kulit adalah salah satu tipe kanker yang memiliki tingkat kejadian yang tinggi. Data statistik GLOBOCAN 2018 yang disusun oleh International Agency for Research on Cancer (IARC) menunjukkan bahwa kanker kulit melanoma dan non melanoma masing – masing menempati posisi 19 dan 5 teratas sebagai kanker paling umum yang terjadi pada pria dan wanita [2]. Statistik yang diberikan oleh American Cancer Society pada peningkatan jumlah kanker baru memberi estimasi bahwa tipe kanker kulit melanoma di Amerika Serikat akan meningkat kurang lebih 100.350 kasus baru [16]. Estimasi tersebut juga menunjukkan bahwa hampir 7.000 orang akan meninggal akibat kanker tersebut. Penelitian menunjukkan bahwa deteksi dan pengobatan dini meningkatkan kemungkinan pasien sembuh sehingga diagnosis melanoma ganas pada pasien menjadi penting untuk mencegah kanker ber metastasis ke organ lain [11]. Terdapat beberapa metode kecerdasan buatan seperti AlexNet [10], Deep Learning Based Neural Networks dan Hybrid Adaboost-Support Vector Machine [14] yang digunakan untuk mengklasifikasi gambar kulit ke beberapa klasifikasi jenis kanker kulit melanoma dan non melanoma. Metode seperti GoogleNet, ResNet-101 dan NasNet-Large [4] juga Inception-ResNet-v2 [1] juga pernah digunakan untuk memprediksi melanoma. Sebuah jurnal yang diterbitkan pada konferensi ICML 2019 membahas mengenai sebuah proposal arsitektur yang mengambil pendekatan yang berbeda pada *model scaling* bernama EfficientNet [17]. Hasil dari jurnal menghasilkan sebuah arsitektur baru bernama EfficientNet dimana EfficientNet-B7 memiliki hasil akurasi yang lebih bagus atau setara dengan *network* lain tapi

dengan ukuran dan *floating point operations per second* (FLOPS) yang lebih kecil. Penelitian kali ini akan berfokus pada penggunaan penghapusan rambut dan *ensembling* untuk menggabungkan arsitektur *Deep Learning* EfficientNet dan ResNet dalam melakukan prediksi melanoma ganas pada *dataset* ISIC 2020.

## 2. TINJAUAN STUDI

Terdapat beberapa metode yang telah diusulkan oleh peneliti untuk menyelesaikan permasalahan klasifikasi lesi kulit. Gessert et al. mengusulkan menggunakan arsitektur EfficientNet, ResNext dan SENE154 yang kemudian disusun menjadi sebuah *ensemble learning*. Pemilihan *ensemble* pada model dilakukan dengan sebuah metode yang diusulkan oleh Gessert et al. dengan mengoptimalkan *cross-validation score*. Metode ini digunakan untuk melakukan klasifikasi pada 8 jenis kanker kulit pada *dataset* ISIC 2019 challenge. Metode yang diusulkan oleh [5] berhasil mencapai *train-test* sebesar 72,5% sedangkan pada *leaderboard* kompetisi, model dapat mencapai 63,6%. Selain itu, pengujian mencoba menggabungkan metadata dari pasien dan mendapatkan 63,4% akurasi. Al-masni et al. mengusulkan menggunakan Inception-v3, ResNet-50, Inception ResNet-v2 dan DenseNet-201 yang digabungkan dengan segmentasi lesi kulit menggunakan *full resolution convolutional neural network* (FrCN) untuk melakukan klasifikasi pada *dataset* ISIC Challenge 2016 dengan 2 kelas, *dataset* ISIC Challenge 2017 dengan 3 kelas dan ISIC Challenge 2018 dengan 7 kelas [1]. Dari hasil pengujian Al-masni et al, *data balancing* yang baik dapat menghasilkan performa diagnosa yang lebih tinggi dan mencegah bias pada kelas dengan data mayoritas. Selain itu *pre - segmentation* juga dapat mengurangi fitur bias sehingga meningkatkan akurasi Inception-ResNet-v2 sebanyak 2,72% dan 4,71% pada kelas melanoma jinak dan ganas. Arsitektur gabungan dari Inception-v3, ResNet-50, Inception-ResNet-v2 dan DenseNet-201 yang digunakan untuk melakukan prediksi berhasil melakukan klasifikasi dengan akurasi masing – masing arsitektur 77.04%, 79.95%, 81.79% dan 81.27% pada *dataset* ISIC 2016, 81.29%, 81.57%, 81.34% dan 73.44% for pada *dataset* ISIC 2017 dan 88.05%, 89.28%, 87.74% dan 88.70% pada *dataset* ISIC 2018. El-Khatib et al. mengusulkan sebuah sistem *decision fusion* dengan menggabungkan model GoogleNet, ResNet-101, NasNet-Large dan feature-based classifier menggunakan Support Vector Machine untuk melakukan klasifikasi pada *dataset* ISIC 2019 dan database gambar PH2 [4]. Hasil dari penggabungan model tersebut menghasilkan akurasi yang lebih tinggi dibanding akurasi masing – masing model dan dapat mencapai 95% akurasi pada database ISIC 2019 serta 93% untuk database PH2. Zunair & Ben Hamza mengusulkan sebuah model MelaNet yang merupakan sistem dua tahap dimana tahap pertama menggunakan CycleGAN (*Generative Adversarial Network*) dan VGG-GAP pada tahap klasifikasi. Penggunaan CycleGAN pada tahap ini digunakan untuk mengatasi permasalahan *class imbalance* dengan melatih sebuah model GAN untuk membuat data sintesis kulit melanoma. VGG-GAP sendiri merupakan model *convolutional neural network* VGG-16 yang digabung dengan *global average pooling* (GAP). Hasil akurasi MelaNet berhasil mencapai 81.18% AUC, lebih tinggi diikuti dengan VGG-GAP dengan augmentasi 10 kali, tanpa augmentasi dan 5 kali dengan akurasi 79.56%, 79.08 dan 78.81%.

## 3. DESAIN SISTEM DAN METODE

### 3.1 Transfer Learning Deep Neural Network Models

Dikarenakan jumlah data yang sedikit, untuk mencapai konvergensi model dengan cepat digunakan *pre-trained model*

yang sudah dilatih pada *dataset* yang jauh lebih besar [19]. Menggunakan *transfer learning* merupakan cara yang standar dan sering digunakan pada kasus dimana data yang ada terbatas [1, 4, 20]. Model yang diajukan menggunakan *pre-trained* EfficientNet B0-B7 dan ResNet-50-v2 tanpa lapisan *fully connected* seperti pada Tabel 1 dan Tabel 2.

**Tabel 1. EfficientNet-B0 baseline network, Setiap Baris Mewakili Sebuah Stage  $i$  dengan lapisan sejumlah  $\hat{L}_i$  dengan resolusi input berukuran  $\hat{H}_i \times \hat{W}_i$  dan Channel  $\hat{C}_i$  dengan operator feature extractor  $\hat{F}_i$**

Stage $i$	Operator $\hat{F}_i$	Resolution $\hat{H}_i \times \hat{W}_i$	#Channels $\hat{C}_i$	#Layers $\hat{L}_i$
1	Conv3x3	256 x 256	32	1
2	MBConv1, k3x3	128 x 128	16	1
3	MBConv6, k3x3	128 x 128	24	2
4	MBConv6, k5x5	64 x 64	40	2
5	MBConv6, k3x3	32 x 32	80	3
6	MBConv6, k5x5	16 x 16	112	3
7	MBConv6, k5x5	16 x 16	192	4
8	MBConv6, k3x3	8 x 8	320	1
9	GAP-8x8 & FC-1	8 x 8	1280	1

**Tabel 2. ResNet-50-v2 network, Setiap Baris Mewakili Sebuah Stage  $i$  dengan lapisan sejumlah  $\hat{L}_i$  dengan operator  $\hat{F}_i$  yang mewakili Residual Block**

Stage $i$	Operator $\hat{F}_i$	#Layers $\hat{L}_i$
1	Conv7x7, 64	1
2	Conv1x1,64 Conv3x3,64 Conv1x1,256	9
3	Conv1x1,128 Conv3x3,128 Conv1x1,512	12
4	Conv1x1,256 Conv3x3,256 Conv1x1,1024	18
5	Conv1x1,512 Conv3x3,512 Conv1x1,2048	9
9	GAP-8x8 & FC-1	1

EfficientNet [17] dan ResNet [8] yang digunakan pada penelitian ini memakai 9 model yaitu EfficientNet B0, EfficientNet B1, EfficientNet B2, EfficientNet B3, EfficientNet B4, EfficientNet B5, EfficientNet B6 dan EfficientNet B7 dan ResNet-50-v2. Bagian dari *feature extractor* model akan dipertahankan dan dilatih ulang dengan *dataset* ISIC 2020. Dikarenakan klasifikasi melanoma merupakan permasalahan klasifikasi biner, digunakan


lapisan *Global Average Pooling* atau GAP yang mengubah *feature map* dari lapisan sebelumnya menjadi sebuah angka dengan melakukan rata – rata. Lapisan ini disambungkan dengan *densely connected layer* dengan *activation function sigmoid* untuk melakukan prediksi biner. Bagian GAP dan *densely connected layer* tidak akan ikut dilatih dengan bagian *feature extractor*. Tabel 1 dan Tabel 2 menampilkan lapisan model yang digunakan.

### 3.2 Dataset Preprocessing dan Analisa


*Dataset* ISIC 2020 [15] yang tersedia terbagi menjadi dua yaitu *train* dan *test* dengan jumlah data *train* 33.126 gambar dan 10.982 data *test*. Rata – rata ukuran data berkisar pada 307.200 sampai 24.000.000 pixel dan tersimpan dalam format DICOM, JPEG dan TFRecord. Untuk mengakomodasi model yang digunakan serta *library tensorflow*, digunakan file JPEG yang di *center crop* menjadi kotak yang kemudian dibuat menjadi ukuran 512x512, 384x384 dan 256x256 dan disimpan dalam format TFRecord.

Untuk melakukan *training*, data dibagi menggunakan *5-fold split cross validaiton* menjadi 5 dengan pembagian 4 bagian untuk *train* dan 1 bagian untuk *validation*. Pembagian dilakukan dengan memperhatikan pembagian distribusi data lesi kulit kanker pada data asli yaitu berkisar 1.7 ~ 1.8%. Selain itu, pada setiap *fold* serta pembagian gambar lesi kulit juga dikelompokkan berdasarkan pasien, dimana seorang pasien bisa memiliki beberapa data lesi kulit.

Gambar lesi kulit memiliki rambut yang menghalangi lesi kulit seperti pada Gambar 1. Hal tersebut dapat membuat model lebih susah untuk mempelajari fitur sehingga merupakan tahap yang penting [4]. Oleh karena itu, digunakan algoritma oleh Koehoorn et al. [12] untuk menghapus rambut pada *dataset* lesi kulit *train* dan *test*. Pelatihan model akan menggunakan *dataset* asli dan *dataset* yang telah dilakukan algoritma penghapusan rambut seperti pada Gambar 2.



Gambar 1. Contoh *dataset* lesi kulit ISIC 2020 dengan rambut menutupi lesi kulit



Gambar 2. Proses *train* dan *test* menggunakan *dataset* asli dan *dataset* yang sudah diolah dengan algoritma *hair removal*

### 3.3 Ensemble Model

Untuk menyelesaikan permasalahan klasifikasi lesi kulit, model yang telah dilatih dengan menggunakan *dataset* gambar lesi kulit melanoma digabungkan menggunakan *ensemble* dengan tujuan meningkatkan akurasi dari klasifikasi. Metode *ensemble* digunakan untuk menggabungkan model menggunakan metode *bagging* atau *bootstrap aggregating* dimana beberapa model berbeda dilatih dan digabungkan (*aggregated*) dengan *majority voting* [3, 9]. Metode ini dapat mengurangi efek buruk dari data poin yang dapat merusak akurasi sebuah model individu dengan mensterarakan efek buruk

tersebut dengan prediksi beberapa model [6]. Beberapa penelitian telah menggunakan aplikasi dari metode ini untuk menggabungkan beberapa model menjadi satu *predictor* [7, 9, 13, 18].

Pada penelitian ini, digunakan metode *ensemble* dimana hasil prediksi model akan ditotal dan di rata – rata seperti pada Persamaan 1.  $f(x)$  merupakan hasil prediksi terakhir, dimana  $f_n(x)$  merupakan model yang akan digabungkan dengan metode *ensemble* dan  $n$  adalah model ke –  $n$ . Hasil terakhir akan dibagi dengan total model ( $N$ ) yang digunakan sehingga menghasilkan sebuah meta – model.

$$f(x) = \frac{1}{N} \sum_{n=1}^N f_n(x) \quad (1)$$

## 4. PENGUJIAN SISTEM

### 4.1 EfficientNet dan ResNet-50-v2

*Five-fold cross validation* dilakukan pada baseline model yang akan digunakan untuk melakukan validasi parameter model. Setiap *fold* akan memiliki 12 file *tfrecord* untuk melakukan *train* dan 3 file *tfrecord* untuk evaluasi hasil dari *train* tersebut. Dilakukan *training* pada model EfficientNet-B0, EfficientNet-B1, EfficientNet-B2, EfficientNet-B3, EfficientNet-B4, EfficientNet-B5, EfficientNet-B6, EfficientNet-B7 dan ResNet-50-v2 sebanyak 15 *epoch* pada masing – masing *fold* menggunakan ukuran gambar yang berbeda. Hasil akurasi diukur menggunakan metrik *Area under the Receiver Operating Characteristic Curve* (AUC). Pengujian performa model akan dilakukan dua pengujian yaitu menggunakan *test dataset* ISIC 2020 dan *dataset* ISIC 2016. Hasil pada Tabel 3 dari *test* menunjukkan nilai AUC yang lebih tinggi dibanding *Val\_AUC* dengan rata – rata nilai diatas 90 AUC dengan nilai AUC maksimal 92.813. Hal ini mengindikasi model berhasil mempelajari fitur lesi kulit dengan cukup baik.

Tabel 3. Akurasi *Test Data* pada Setiap Model Diurutkan Rendah ke Tinggi

Model	AUC (%)
ResNet-50-v2	90.196
EfficientNet-B1	91.22
EfficientNet-B0	91.961
EfficientNet-B3	92.077
EfficientNet-B2	92.087
EfficientNet-B7	92.365
EfficientNet-B4	92.468
EfficientNet-B5	92.572
<b>EfficientNet-B6</b>	<b>92.813</b>

### 4.2 Hair Removal Dataset

Metodologi pelatihan akan mengikuti cara yang sama dengan pengujian 4.1 dimana setiap model akan dilatih dengan *dataset* yang telah dilakukan *preprocessing hair removal*. Pengujian akan diukur menggunakan AUC dari prediksi *test data*.

**Tabel 4. Akurasi Test Data pada Setiap Model dengan Menggunakan Dataset yang Diolah dengan Hair Removal Diurutkan Rendah ke Tinggi**

Model	AUC (%)
ResNet-50-v2	89.775
EfficientNet-B1	90.389
EfficientNet-B2	91.425
EfficientNet-B6	91.502
EfficientNet-B0	91.605
EfficientNet-B5	91.641
EfficientNet-B7	91.742
EfficientNet-B3	91.927
<b>EfficientNet-B4</b>	<b>92.03</b>

Dari hasil pada Tabel 4 tersebut model yang dilatih dengan menggunakan dataset yang telah dilakukan hair removal dapat mencapai nilai yang tinggi dengan nilai tertinggi mencapai 92.03%. Namun, hasil tersebut memiliki akurasi yang lebih rendah dibanding model yang dilatih dengan dataset asli. Penurunan akurasi dapat diduga karena pada data yang digunakan luas kulit biasa dan lesi kulit memiliki rasio yang cenderung besar ke kulit biasa. Selain itu, ukuran lesi kulit yang bervariasi juga mempengaruhi, dimana lesi kulit berukuran kecil lebih susah untuk dipelajari. Hal ini mengakibatkan model untuk mempelajari lebih banyak fitur pada bagian kulit normal dibanding lesi kulit.

### 4.3 Ensembling Bagging Method

Model ini merupakan hasil ensemble dari model yang telah dilatih menjadi satu meta – model yang memiliki tingkat akurasi yang lebih tinggi dibandingkan apabila masing – masing model melakukan prediksi pada dataset yang sama. Model terdiri dari kombinasi model yang telah dilatih pada pengujian sebelumnya. Ensemble dilakukan pada semua model dan pada model dengan akurasi diatas rata – rata dari semua model serta pada model yang dilatih pada pengujian 4.1 dan 4.2.

**Tabel 5. Hasil Prediksi Test Menggunakan Ensemble dengan Kombinasi Berbagai Model Diurutkan dari Rendah ke Tinggi**

Ensemble Model	AUC (%)
Pengujian 4.2 Model Average	92.493
All Model Average	92.892
Pengujian 4.1 Model Average	92.997
<b>10 Best Model Average</b>	<b>93.108</b>

Pada Tabel 5, dapat dilihat bahwa melakukan ensemble dengan model diatas rata – rata semua model memiliki hasil terbaik dengan hasil akurasi 92.108%.

## 5. KESIMPULAN

Model EfficientNet dan ResNet memiliki kemampuan untuk melakukan klasifikasi lesi kulit melanoma dengan hasil tertinggi mencapai 92.813% AUC. Hal ini menunjukkan model dapat

melakukan generalisasi data lesi kulit dengan cukup baik sehingga dapat melakukan klasifikasi lesi kulit. Menghilangkan rambut dari gambar lesi kulit menunjukkan penurunan dari akurasi AUC dari model. Hal ini mengindikasikan bahwa pada model yang dilatih menggunakan dataset hair removed mempelajari fitur dari kulit biasa sehingga mengganggu dalam proses klasifikasi. Menghilangkan rambut dapat mengurangi fitur yang tidak berhubungan dengan lesi kulit namun diperlukan juga untuk menyempitkan daerah yang dipelajari. Dari hasil ensemble semua model yang telah dilatih, didapat prediksi terbaik menggunakan 10 model terbaik dan metode model averaging dengan akurasi prediksi AUC 93.108%. Akurasi tersebut merupakan peningkatan dari akurasi individu model tertinggi sebesar 0.295%.

## 6. DAFTAR PUSTAKA

- [1] Al-masni, M.A., Kim, D.H. and Kim, T.S. 2020. Multiple skin lesions diagnostics via integrated deep convolutional networks for segmentation and classification. *Computer Methods and Programs in Biomedicine*. 190. DOI:https://doi.org/10.1016/j.cmpb.2020.105351.
- [2] Bray, F., Ferlay, J., Soerjomataram, I., Siegel, R.L., Torre, L.A. and Jemal, A. 2018. Global cancer statistics 2018: GLOBOCAN estimates of incidence and mortality worldwide for 36 cancers in 185 countries. *CA: A Cancer Journal for Clinicians*. 68, 6, 394–424. DOI:https://doi.org/10.3322/caac.21492.
- [3] Domingos, P. 1997. Why Does Bagging Work? A Bayesian Account and its Implications. *Proceedings of the Third International Conference on Knowledge Discovery and Data Mining (KDD'97)* (Newport Beach, CA), 158.
- [4] El-Khatib, H., Popescu, D. and Ichim, L. 2020. Deep learning-based methods for automatic diagnosis of skin lesions. *Sensors (Switzerland)*. 20, 6. DOI:https://doi.org/10.3390/s20061753.
- [5] Gessert, N., Nielsen, M., Shaikh, M., Werner, R. and Schlaefer, A. 2020. Skin lesion classification using ensembles of multi-resolution EfficientNets with meta data. *MethodsX*. 7, 100864. DOI:https://doi.org/10.1016/j.mex.2020.100864.
- [6] Grandvalet, Y. 2004. Bagging equalizes influence. *Machine Learning*. 55, 3, 251–270. DOI:https://doi.org/10.1023/B:MACH.0000027783.34431.42.
- [7] Guo, P., Xue, Z., Mtema, Z., Yeates, K., Ginsburg, O., Demarco, M., Rodney Long, L., Schiffman, M. and Antani, S. 2020. Ensemble deep learning for cervix image selection toward improving reliability in automated cervical precancer screening. *Diagnostics*. 10, 7. DOI:https://doi.org/10.3390/diagnostics10070451.
- [8] He, K., Zhang, X., Ren, S. and Sun, J. 2016. Identity mappings in deep residual networks. *Lecture Notes in Computer Science (including subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 630–645.
- [9] Heisler, M., Karst, S., Lo, J., Mammo, Z., Yu, T., Warner, S., Maberley, D., Beg, M.F., Navajas, E. V. and Sarunic, M. V. 2020. Ensemble deep learning for diabetic retinopathy detection using optical coherence tomography angiography. *Translational Vision Science and Technology*. 9, 2, 1–11. DOI:https://doi.org/10.1167/tvst.9.2.20.

- [10] Hosny, K.M., Kassem, M.A. and Fouad, M.M. 2020. Classification of Skin Lesions into Seven Classes Using Transfer Learning with AlexNet. *Journal of Digital Imaging*. 1–10. DOI:<https://doi.org/10.1007/s10278-020-00371-9>.
- [11] Jerant, A.F., Johnson, J.T., Sheridan, C.D. and Caffrey, T.J. 2000. Early Detection and Treatment of Skin Cancer. *American Family Physician*. 62, 2, 357–368.
- [12] Koehoorn, J., Sobiecki, A., Rauber, P., Jalba, A. and Telea, A. 2016. Efficient and Effective Automated Digital Hair Removal from Dermoscopy Images. *Mathematical Morphology - Theory and Applications*. 1, 1, 1–17. DOI:<https://doi.org/10.1515/mathm-2016-0001>.
- [13] Neto, H.A., Tavares, W.L.F., Ribeiro, D.C.S.Z., Alves, R.C.O., Fonseca, L.M. and Campos, S.V.A. 2019. On the utilization of deep and ensemble learning to detect milk adulteration. *BioData Mining*. 12, 1. DOI:<https://doi.org/10.1186/s13040-019-0200-5>.
- [14] Premaladha, J. and Ravichandran, K.S. 2016. Novel Approaches for Diagnosing Melanoma Skin Lesions Through Supervised and Deep Learning Algorithms. *Journal of Medical Systems*. 40, 4, 1–12. DOI:<https://doi.org/10.1007/s10916-016-0460-2>.
- [15] Rotemberg, V. et al. 2020. A Patient-Centric Dataset of Images and Metadata for Identifying Melanomas Using Clinical Context.
- [16] Siegel, R.L., Miller, K.D. and Jemal, A. 2020. Cancer statistics, 2020. *CA: A Cancer Journal for Clinicians*. 70, 1, 7–30. DOI:<https://doi.org/10.3322/caac.21590>.
- [17] Tan, M. and Le, Q. V. 2019. EfficientNet: Rethinking model scaling for convolutional neural networks. *36th International Conference on Machine Learning, ICML 2019*, 10691–10700.
- [18] Wei, X., Gao, M., Yu, R., Liu, Z., Gu, Q., Liu, X., Zheng, Z., Zheng, X., Zhu, J. and Zhang, S. 2020. Ensemble deep learning model for multicenter classification of thyroid nodules on ultrasound images. *Medical Science Monitor*. 26, . DOI:<https://doi.org/10.12659/MSM.926096>.
- [19] Yosinski, J., Clune, J., Bengio, Y. and Lipson, H. 2014. How transferable are features in deep neural networks? *Advances in Neural Information Processing Systems*. 4, January, 3320–3328.
- [20] Zunair, H. and Ben Hamza, A. 2020. Melanoma detection using adversarial training and deep transfer learning. *Physics in Medicine and Biology*. 65, 13, 135005. DOI:<https://doi.org/10.1088/1361-6560/ab86d3>.