

Implementasi *ShuffleNet V2* Pada Klasifikasi Penyakit Kulit *Benign* dan *Malignant*

MUHAMMAD RIFALDI BADU^{1*}, JASMAN PARDEDE¹

¹Program Studi Informatika, Institut Teknologi Nasional
Email: rifaldibadu@gmail.com

Received 31 01 2023 | Revised 07 02 2023 | Accepted 07 02 2023

ABSTRAK

Penyakit kulit atau kanker kulit disebabkan oleh adanya pertumbuhan abnormal sel kulit. Kanker kulit dapat diklasifikasikan menjadi dua kategori yaitu tumor kulit benign (jinak) atau malignant (tumor ganas) dengan karakteristik yang hampir sama. Dengan ini, deteksi dini dan diagnosis yang akurat diperlukan untuk membantu mengidentifikasi kanker kulit benign dan malignant. Beberapa metode telah dilakukan untuk membantu deteksi penyakit kulit salah satunya menggunakan computer vision. Pada penelitian ini, dirancang sebuah sistem yang dapat mengklasifikasi penyakit kulit pada citra dermoskopi dengan menggunakan arsitektur ShuffleNet V2. Pada hasil eksperimen, diuji 5 varian model ShuffleNet V2 dengan menggunakan hyperparameter yaitu optimizer adam, learning rate 0.0001, batch size 16 dan epoch 40. Performa model terbaik berdasarkan hasil evaluasi merupakan model ShuffleNetV2_1.0_1_373 yang mendapatkan 87.2% accuracy, 87.5% precision, 87.0% recall dan 87.2% F1 score.

Kata kunci: CNN, Lightweight CNN, ShuffleNet V2, Kanker Kulit, benign, malignant

ABSTRACT

Skin disease, or skin cancer, is caused by the abnormal growth of skin cells. Skin cancer can be classified into two categories, namely benign (benign) or malignant (malignant tumor) skin tumors, with almost the same characteristics. With it, early detection and accurate diagnosis are needed to help identify benign and malignant skin cancer. Several methods have been developed to aid in the detection of skin diseases, one of which is the use of computer vision. In this study, a system was designed that could classify skin diseases on dermoscopy images using the ShuffleNet V2 architecture. In the experimental results, 5 variants of the ShuffleNet V2 model were tested using hyperparameters such as adam optimizer with a learning rate of 0.0001, batch size of 16, and epoch 40. The model with the best performance based on the evaluation results was the ShuffleNetV2_1.0_1_373 model, which obtained 87.2% accuracy, 87.5% precision, 87.0% recalls, and an 87.2% F1 score.

Keywords: CNN, Lightweight CNN, ShuffleNet V2, Skin Cancer, benign, malignant

1. PENDAHULUAN

Penyakit Kulit atau *Skin cancer* telah menjadi penyakit yang paling tersebar luas secara global. Terjadinya kanker kulit non-melanoma ataupun melanoma telah berkembang dalam beberapa dekade berikutnya (**Rezaoana, Hossain, & Andersson, 2020**). Kanker kulit biasa terjadi pada bagian kulit yang terpapar sinar matahari dan beberapa bagian yang tidak terpapar sinar matahari. Kanker kulit memiliki pertumbuhan sel kulit yang tidak normal. Deteksi dini dapat menyelamatkan nyawa manusia hingga 95% (**Manasa & Murthy, 2021**).

Karena pentingnya deteksi dini, banyak pekerjaan telah didedikasikan untuk meningkatkan akurasi dan skala metode diagnostik. Pada tahun 2016 dan 2017, *International Skin Imaging Collaboration* (ISIC), kemitraan global yang telah membuat sebuah *repository* gambar *dermoscopic* terbesar di dunia yang tersedia untuk umum, menyelenggarakan tolok ukur publik pertama untuk deteksi melanoma dalam gambar dermoscopic, berjudul "*Skin Lesion Analysis Towards Melanoma Detection*", di *IEEE International Symposium of Biomedical Imaging* (ISBI) (**Codella et al., 2019**). *Skin lesion* dapat diklasifikasikan menjadi dua kategori yaitu tumor kulit *benign* (jinak) seperti nevus, atau *malignant* (tumor ganas) seperti melanoma yang merupakan jenis kanker kulit yang paling jarang ditemukan tetapi paling berbahaya. Hingga beberapa tahun terakhir, diagnosis dengan bantuan komputer digunakan untuk deteksi dini kanker kulit dari hasil gambar dermoskopi (**Benyahia, Meftah, & Lézoray, 2021**). Menurut uraian sebelumnya, dapat diartikan jika diagnosis dengan bantuan komputer pada gambar dermoskopi digunakan agar dapat melakukan deteksi dini pada penyakit kulit *benign* dan *malignant*.

Diagnosis dengan bantuan komputer seperti ini masih merupakan tugas yang menantang. Dalam beberapa tahun terakhir telah banyak aplikasi teknik pembelajaran mesin (ANN, SVM, KNN) yang berhasil serta pendekatan deep learning khususnya *Convolutional Neural Network* (CNN) (**Benyahia et al., 2021**). CNN memiliki kerangka kerja konseptual yang signifikan, termasuk pembagian bobot, persepsi dan ruang pengambilan sampel domain, yang menjamin perpindahan relative, distorsi dan karakteristik penskalaan (**Luqman Hakim, Sari, & Handhajani, 2021**).


Terdapat berbagai jenis arsitektur CNN yang mempunyai konsep dan komposisi yang berbeda-beda yang salah satunya adalah jenis *lightweight* CNN yang desain jaringannya diutamakan untuk merancang sebuah *network calculation method* yang lebih efisien. Metode perhitungan disini ditujukan pada metode konvolusi, sehingga mengurangi parameter jaringan, tetapi tanpa mengurangi kinerja jaringan (**Zhou, Chen, Wang, & Huan, 2020**). *Lightweight* CNN sendiri mempunyai beberapa arsitektur yaitu, *SqueezeNet*, *MobileNet*, *EfficientNet*, *MixNet* dan *ShuffleNet*. Salah satu arsitektur *lightweight* CNN yaitu *ShuffleNet* pertama kali diusulkan oleh (**Zhang, Zhou, Lin, & Sun, 2018**) dengan nama *ShuffleNet V1* yang mendapatkan 70.9% *top-1 accuracy* pada klasifikasi citra ImageNet dan model terbaru yaitu *ShuffleNet V2* (**Ma, Zhang, Zheng, & Sun, 2018**) mendapatkan 75.4%.

Penelitian ini akan melakukan pembuatan model dengan arsitektur *ShuffleNet V2* yang dapat digunakan untuk melakukan identifikasi penyakit kulit atau *skin cancer benign* (jinak) dan *malignant* (ganas). Penelitian ini akan menggunakan HAM10000 *dataset* (**Tschandl, Rosendahl, & Kittler, 2018**) yang telah dirangkum oleh Claudio Fanconi di Kaggle.com sebagai *dataset* untuk melatih model *ShuffleNet V2* dalam klasifikasi penyakit kulit *benign* dan *malignant*. Penerapan arsitektur *ShuffleNet V2* pada klasifikasi penyakit kulit diharapkan mendapatkan model terbaik berdasarkan hasil pengujian terhadap model.

2. METODE PENELITIAN

2.1. Deep Learning

Metode *deep learning* adalah metode *representation-learning* atau *feature* dengan beberapa level fitur yang diperoleh melalui penyusunan modul sederhana namun *non-linear* yang masing-masing mengubah fitur pada satu level (dimulai dengan *input* mentah) sampai menjadi fitur pada level yang lebih tinggi. *Convolutional neural network* yang merupakan bagian dari *deep learning* terdiri dari beberapa lapisan termasuk *input*, *convolution*, *sub-layer* dan lapisan non linear dengan *fully connected* dan aktivasi *softmax* sering digunakan pada lapisan terakhir (Lecun et al., 2015; Nguyen Quoc & Truong Hoang, 2020). Ilustrasi arsitektur CNN ditunjukkan pada Gambar 1.




Gambar 1. Arsitektur *Convolutional Neural Network*

2.2. Lightweight CNN

Lightweighting adalah konsep yang diusulkan dalam beberapa tahun terakhir, berfokus pada penyelesaian masalah ukuran dan kecepatan model. Operasi dasar CNN adalah melakukan ekstraksi konvolusi pada area lokal pada citra. Tetapi operasi konvolusi standar biasa memiliki beberapa kelemahan seperti ketika jumlah saluran fitur bertambah, jumlah parameter kernel konvolusi juga akan menjadi besar, sehingga jumlah perhitungan juga meningkat. Untuk mengatasi masalah ini beberapa metode *convolution* muncul yang salah satunya adalah *depthwise separable convolution* (Zhou et al., 2020).

2.3. ShuffleNet V2

Model *ShuffleNet V2* merupakan jenis *lightweight CNN* yang diusulkan oleh Megvii dan Universitas Tsinghua (Ma et al., 2018) yang dirancang untuk *small network* dengan prinsip *bottleneck*. *ShuffleNet V2* merupakan lanjutan dari model sebelumnya yang menggunakan operasi *depthwise separable convolution* dan *channel shuffle* dengan tujuan untuk meminimalkan jumlah parameter yang dihasilkan.



Gambar 2. Diagram Blok Arsitektur *ShuffleNet V2*

Pada diagram blok *ShuffleNet V2*, terdapat beberapa operasi konvolusi, fungsi non linear dan stage yang terdiri dari dua blok *shufflenet*. Terdapat tiga *stage* yang merupakan gabungan dari dua blok *shufflenet* yang masing-masing *stage* mempunyai jumlah repetisi pada Block2. Selanjutnya pada tahap klasifikasi terdapat operasi *global average pooling*, *fully connected* dan diikuti dengan fungsi aktivasi *softmax*. Tabel 1 menunjukkan struktur keseluruhan dari arsitektur *ShuffleNet V2*.

Tabel 1. Arsitektur *ShuffleNet V2*


Layer	Output Size	KSize	Stride	Repeat	Output Channel
Image	224x224				3
Conv1	112x112	3x3	2	1	24
MaxPool	56x56	3x3	2	1	24
Stage2	28x28		2	1	116
	28x28		1	3	116
Stage3	14x14		2	1	232
	14x14		1	7	232
Stage4	7x7		2	1	464
	7x7		1	3	464
Conv5	7x7	1x1	1	1	1024
GlobalPool	1x1	7x7			
FC					2
Softmax					2

Pada Tabel 1 menunjukkan bagaimana perubahan *size* dari citra *input* beserta *output channel*. Dimulai pada lapisan konvolusi (Conv1) dengan 24 *filter* lalu *maxpool* yang masing-masing mempunyai *stride* = 2 dan ukuran *kernel* 3x3. Selanjutnya pada bagian *stage* terlihat bahwa *output shape* mengalami perubahan tepat saat masuk ke dalam tahap pertama *stage* atau pada Block1 dengan Block2 yang tetap mempertahankan nilai *output shape*. Setiap *stage* akan

menghasilkan perubahan pada *output shape* dengan nilai ganda pada *output channel*. Perubahan pada *output shape* ini mengikuti *bottleneck ratio* yaitu 1 dengan jumlah *output channel* atau jumlah *filter* adalah 116 pada Stage2 (Ma et al., 2018).

2.3.1 ShuffleNet Block

Model pada CNN tradisional biasanya memiliki lapisan *convolution*, *pooling* dan *fully connected*. Keberadaan *kernel* konvolusi yang besar membuat model menjadi besar secara komputasi (Liu, Yao, Yang, & Li, 2019). *ShuffleNet V2* memiliki sebuah *block* yang memiliki sebuah kombinasi *depthwise convolution* dan kernel konvolusi 1x1 atau *pointwise convolution*. Penggabungan ini dinamakan *depthwise separable convolution* yang digunakan untuk menggantikan operasi *convolutional* biasa. *Block* dari *shufflenet* ditunjukkan pada Gambar 3.



Gambar 3. Unit Block ShuffleNet V2: (a) Block1 Spatial Down Sampling, (b) Block2 Basic Unit (Ma et al., 2018)

Gambar 3 menunjukkan kedua unit *shufflenet block* yang terdiri dari *pointwise convolution*, *batch normalization*, fungsi *ReLU*, *depthwise convolution*, *concat* dan *channel shuffle* dengan perbedaan pada jumlah *stride* dan operasi *channel split* pada Block2 basic unit.


- a. Block1 mempunyai operasi *depthwise convolution* dengan nilai *stride* adalah 2 yang bertujuan untuk melakukan *down sampling* pada *input size*. Input akan melalui dua operasi secara paralel. Pada operasi pertama terdapat 1x1 *convolution* yang dilanjutkan oleh *depthwise separable convolution*, dan operasi kedua yaitu *skip connection* terdapat *depthwise separable convolution* yang masing-masing operasi ini akan dijumlahkan nilai *output channels* melalui *concatenate* lalu diikuti dengan *channel shuffle* melakukan

pengacakan urutan *output channel* untuk memastikan pertukaran informasi fitur antara dua cabang (**Liu et al., 2019**).

- b. Block2 merupakan *basic unit* dengan operasi yang sama dan jumlah stride adalah 1. Pertama *input channel* akan dibagi dua menggunakan *channel split* sebelum dilakukan operasi secara paralel seperti pada Block1. Berbeda dengan Block1, operasi kedua hanyalah sebuah *skip connection* yang mempertahankan nilai *input*. *Output shape* dari Block2 akan sama dengan nilai *input* dan dapat dilakukan repetisi untuk meningkatkan nilai parameter.

2.4 Penyakit Kulit *Benign* dan *Malignant*


Penyakit kulit atau skin cancer merupakan sebuah pertumbuhan abnormal sel kulit. Jenis *benign* dan *malignant* adalah penyakit kanker kulit yang paling umum diderita orang (**Hasan et al., 2021**). Tahap awal pada kanker kulit *malignant* sering kali dianggap *benign* karena karakteristik yang hampir sama. Untuk mencegah hal ini terjadi maka diagnose dini perlu dilakukan. Hingga beberapa tahun terakhir, diagnosis dengan bantuan komputer digunakan untuk deteksi dini kanker kulit dari hasil gambar dermoskopi (**Benyahia et al., 2021**). Gambar kedua jenis *skin cancer* ditunjukkan pada Gambar 4.



Gambar 4. Kanker Kulit *Benign* dan *Malignant*

2.5 Perancangan

Perancangan sistem pada penelitian klasifikasi penyakit kulit *benign* dan *malignant* menggunakan *ShuffleNet V2* ini terdapat tahapan-tahapan yang menunjukkan bagaimana model dibuat yang ditunjukkan pada Gambar 5.



Gambar 5. Diagram Blok Sistem

Input yang berupa citra dermoskopi kanker kulit *benign* dan *malignant* yang berasal dari repositori HAM10000 *dataset* (Tschandl et al., 2018). Dibagi menjadi *training data*, *validation data* dan *testing data*. Pada *input training* untuk proses *training* terdapat *preprocessing* dengan melakukan *resize* ukuran piksel menjadi 224 x 224 piksel dengan 3 buah *channel* RGB (*Red*, *Green* dan *Blue*) dan dilanjutkan dengan *image normalization*. Proses selanjutnya adalah *training* pada citra menggunakan arsitektur *ShuffleNet V2*. Hasil dari proses *training* pada *dataset training* akan dilakukan pengujian menggunakan data *validation* yang juga dilakukan *preprocessing* untuk mengukur bobot dan akurasi model terhadap *dataset* baru. Setelah proses *training* keseluruhan selesai, maka proses *testing* dilakukan untuk mengevaluasi model terbaik yang dihasilkan oleh proses *training* terhadap data *testing* menggunakan *confusion matrix* agar dapat mengetahui performa dari model yang telah dibuat.

2.5 Confusion Matrix

Confusion matrix (juga dikenal sebagai *error matrix*) merupakan pendekatan kuantitatif untuk mendeskripsikan akurasi kategorisasi gambar, dan merupakan tabel yang meringkas hasil model klasifikasi. *Confusion matrix* didasarkan pada *true positive* (TP), dan *false positive* (FP), *true negative* (TN), *false negative* (FN) (Hasan et al., 2021). Berikut beberapa persamaan pengukuran *confusion matrix*.

$$Accuracy = \frac{TP + TN}{TP + FP + TN + FN} \quad (1)$$

Persamaan (1) menunjukkan perhitungan *accuracy*. *Accuracy* merupakan perbandingan jumlah prediksi benar dengan total keseluruhan prediksi.

$$Precision = \frac{TP}{TP + FP} \quad (2)$$

Persamaan (2) menunjukkan perhitungan *precision*. *Precision* merupakan perbandingan jumlah prediksi benar terhadap klasifikasi positif dengan total prediksi benar dan salah terhadap semua klasifikasi positif.

$$Recall = \frac{TP}{TP + FN} \quad (3)$$

Persamaan (3) menunjukkan perhitungan *recall*. *Recall* merupakan perbandingan jumlah prediksi benar terhadap klasifikasi benar dengan total prediksi benar terhadap klasifikasi positif dan prediksi salah terhadap klasifikasi negatif.


$$F - Measure = 2 * \frac{Precision * Recall}{Precision + Recall} \quad (4)$$

Persamaan (4) menunjukkan perhitungan *F-Measure*. *F-Measure* merupakan perhitungan sederhana dari perbandingan antara nilai *precision* dan *recall*.

3. HASIL DAN PEMBAHASAN

3.1 Penggunaan Dataset

Pada *dataset* citra penyakit kulit *benign* dan *malignant* yang didapat dari HAM10000 *dataset* (Tschandl et al., 2018) melalui Claudio Fanconi. Total data citra penyakit kulit sebanyak 3,172 citra. Terdapat dua kelas citra pada *dataset* ini yaitu *benign* dan *malignant* dengan masing-masing mempunyai total 1,760 citra dan 1,412 citra. Data citra yang akan digunakan pada proses *training* dan *testing* dapat dilihat pada Gambar 6.



Gambar 6. Grafik Penggunaan Dataset

3.2 Training Model


Tahap *training* ditujukan untuk membuat sebuah model terbaik menggunakan arsitektur *ShuffleNet V2* terhadap *dataset* citra dermoskopi penyakit kulit. Proses *training* ini dibangun menggunakan *google colab* berdasarkan *hyperparameter* yang sudah ditentukan yaitu *adam* sebagai *optimizer*, *learning rate* 0.0001, 40 *epochs*, dan *batch size* adalah 16. Pada penelitian ini akan melakukan proses *training* terhadap 5 varian model berbeda yang masing-masing menggunakan *bottleneck ratio* yang sama yaitu 1 serta *input size* citra yaitu 224 x 224 piksel. Varian model dapat dilihat pada Tabel 2.

Tabel 2. Variasi model berdasarkan jumlah repetisi *stage*

No	Model	Jumlah Repetisi Stage (Block2)	Jumlah Parameter
1	<i>ShuffleNetV2_1.0_1_131</i>	1,3,1	2,625,078
2	<i>ShuffleNetV2_1.0_1_242</i>	2,4,2	3,209,718

No	Model	Jumlah Repetisi Stage (Block2)	Jumlah Parameter
3	<i>ShuffleNetV2_1.0_1_373</i>	3,7,3	4,020,790
4	<i>ShuffleNetV2_1.0_1_484</i>	4,8,4	4,605,430
5	<i>ShuffleNetV2_1.0_1_595</i>	5,9,5	5,190,070


Hasil proses *training* pada setiap model menunjukkan akurasi berdasarkan *validation accuracy* tertinggi yaitu 0.8598 dengan *loss* 0.6444 dan *training accuracy* yaitu 0.9694 dengan *loss* 0.0858 pada model 4 dengan durasi *training* adalah 5 jam 31 menit. Grafik *accuracy* dan *loss* ditunjukkan pada Gambar 6.



Gambar 7. Grafik *Accuracy* dan *Loss*


3.3 Pengujian Kinerja Model

Pengujian kinerja model dilakukan melalui pengukuran *accuracy*, *precision*, *recall* dan *f-measure* pada model yang sudah melewati proses *training* terhadap *data testing*. Pengujian ini dilakukan terhadap 5 varian model yang sudah dilatih yang dibedakan dengan jumlah repetisi *stage*. Dalam proses pengujian didapatkan akurasi tertinggi pada model 3 dengan 87.2% *accuracy*, 87.5% *precision*, 87.0% *recall*, 87.2% *f-measure* yang ditunjukkan pada Gambar 8.



Gambar 8. Grafik Pengujian Kinerja Model

Pada penelitian ini terdapat 5 varian model yang diurutkan menurut jumlah total parameter yang dihasilkan berdasarkan kedalaman model. Jumlah parameter akan mempengaruhi waktu *testing* atau kecepatan model dalam melakukan klasifikasi. Berdasarkan tingkat akurasi pada pengujian kinerja model dapat dilihat bahwa model 3 yang merupakan model dengan kedalaman atau jumlah repetisi Block2 pada Stage2, Stage3, Stage4 adalah masing-masing 3,7,3 mempunyai nilai tertinggi dari semua model yang diujikan. Gambar 9 menunjukkan hasil perbandingan akurasi dan rata-rata kecepatan dari 5 varian model yang diujikan.



Gambar 9. Grafik Perbandingan Akurasi Terhadap Kecepatan Model

Berdasarkan hasil dari pengujian, ditunjukkan bahwa terjadi penurunan tingkat akurasi di antara Model 1 dan Model 2, kenaikan dengan nilai tertinggi pada Model 3 dan penurunan pada Model 4 serta pada Model 5 yang memiliki kecepatan rata-rata paling lama dengan nilai terendah.

Pada pengujian kinerja sistem varian model ini menunjukkan nilai *loss* yang dihasilkan oleh setiap model dengan Model 3 yang memiliki hasil *loss* paling rendah. Hasil eksperimen perbandingan model berdasarkan *accuracy precision recall f-measure* nilai *loss* serta kecepatan ditunjukkan pada Tabel 3.

Tabel 3. Perbandingan Pengujian Variasi model

Model	Accuracy	Precision	Recall	F-Measure	Loss	Kecepatan (detik/citra)
1	86.6%	86.5%	87.0%	84.1%	0.5007	0.038
2	84.1%	86.0%	85.5%	84.5%	0.7524	0.057
3	87.2%	87.5%	87.0%	87.2%	0.4260	0.064
4	85.9%	86.5%	86.5%	86.0%	0.6444	0.072
5	83.2%	83.0%	83.5%	83.1%	0.5239	0.082

4. KESIMPULAN

Hasil pengujian kinerja model terhadap klasifikasi penyakit kulit *benign* dan *malignant* menunjukkan model dengan arsitektur *ShuffleNetV2_1.0_1_373* atau yang memiliki jumlah repetisi Block2 pada *stage* sebanyak 3,7,3 merupakan model yang memiliki nilai *accuracy* yaitu

87.2%, *precision* 87.5%, *recall* 87.0% dan *f-measure* 87.2% dengan akurasi, presisi dan *f-measure* tertinggi dibandingkan dengan varian model yang lain. Berdasarkan hasil eksperimen yang dilakukan, penentuan kedalaman model atau repetisi pada *stage* berpengaruh pada kinerja sistem yang dibangun. Pada model yang kedalaman atau jumlah repetisi *stage* dikurangi mendapatkan nilai akurasi yang lebih rendah dibandingkan dengan jumlah repetisi *default*. Pada model yang kedalaman atau jumlah repetisi *stage* ditambah juga mengalami penurunan pada nilai akurasi walaupun jumlah *parameter* bertambah.

DAFTAR PUSTAKA

- Benyahia, S., Meftah, B., & Lézoray, O. (2021). Skin Lesion Classification Using Convolutional Neural Networks Based on Multi-Features Extraction. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 13052 LNCS, 466–475. https://doi.org/10.1007/978-3-030-89128-2_45
- Codella, N., Rotemberg, V., Tschandl, P., Celebi, M. E., Dusza, S., Gutman, D., ... Halpern, A. (2019). *Skin Lesion Analysis Toward Melanoma Detection 2018: A Challenge Hosted by the International Skin Imaging Collaboration (ISIC)*. 1–12. Retrieved from <http://arxiv.org/abs/1902.03368>
- Hasan, M. R., Fatemi, M. I., Monirujjaman Khan, M., Kaur, M., & Zaguia, A. (2021). Comparative Analysis of Skin Cancer (Benign vs. Malignant) Detection Using Convolutional Neural Networks. *Journal of Healthcare Engineering*, 2021, 1–17. <https://doi.org/10.1155/2021/5895156>
- Lecun, Y., Bengio, Y., & Hinton, G. (2015). Deep learning. *Nature*, 521(7553), 436–444. <https://doi.org/10.1038/nature14539>
- Liu, H., Yao, D., Yang, J., & Li, X. (2019). Lightweight convolutional neural network and its application in rolling bearing fault diagnosis under variable working conditions. *Sensors (Switzerland)*, 19(22). <https://doi.org/10.3390/s19224827>
- Luqman Hakim, Sari, Z., & Handhajani, H. (2021). Klasifikasi Citra Pigmen Kanker Kulit Menggunakan Convolutional Neural Network. *Jurnal RESTI (Rekayasa Sistem Dan Teknologi Informasi)*, 5(2), 379–385. <https://doi.org/10.29207/resti.v5i2.3001>
- Ma, N., Zhang, X., Zheng, H. T., & Sun, J. (2018). Shufflenet V2: Practical guidelines for efficient cnn architecture design. *Lecture Notes in Computer Science (Including Subseries Lecture Notes in Artificial Intelligence and Lecture Notes in Bioinformatics)*, 11218 LNCS, 122–138. https://doi.org/10.1007/978-3-030-01264-9_8
- Manasa, K., & Murthy, D. G. V. (2021). Skin Cancer Detection Using VGG-16. *European Journal of Molecular & Clinical Medicine*, 8(1), 1419–1426.
- Nguyen Quoc, T., & Truong Hoang, V. (2020). Medicinal Plant identification in the wild by using CNN. *International Conference on ICT Convergence, 2020-Octob*, 25–29. <https://doi.org/10.1109/ICTC49870.2020.9289480>
- Rezaoana, N., Hossain, M. S., & Andersson, K. (2020). Detection and Classification of Skin Cancer by Using a Parallel CNN Model. *Proceedings of 2020 IEEE International Women in Engineering (WIE) Conference on Electrical and Computer Engineering, WIECON-ECE 2020*, 380–386. <https://doi.org/10.1109/WIECON-ECE52138.2020.9397987>
- Tschandl, P., Rosendahl, C., & Kittler, H. (2018). Data descriptor: The HAM10000 dataset, a large collection of multi-source dermatoscopic images of common pigmented skin lesions. *Scientific Data*, 5, 1–9. <https://doi.org/10.1038/sdata.2018.161>
- Zhang, X., Zhou, X., Lin, M., & Sun, J. (2018). ShuffleNet: An Extremely Efficient Convolutional Neural Network for Mobile Devices. *Proceedings of the IEEE Computer Society Conference on Computer Vision and Pattern Recognition*, 6848–6856. <https://doi.org/10.1109/CVPR.2018.00716>

Zhou, Y., Chen, S., Wang, Y., & Huan, W. (2020). Review of research on lightweight convolutional neural networks. *Proceedings of 2020 IEEE 5th Information Technology and Mechatronics Engineering Conference, ITOEC 2020*, (Itoec), 1713–1720. <https://doi.org/10.1109/ITOEC49072.2020.9141847>