

KLASIFIKASI CITRA KANKER KULIT MENGGUNAKAN ARSITEKTUR MOBILENET



TESIS

Diajukan sebagai salah satu syarat untuk memperoleh gelar
Magister Ilmu Komputer (M.Kom)

ELLY FIRASARI

14002379

Program Studi Ilmu Komputer (S2)

Fakultas Teknologi Informasi

Universitas Nusa Mandiri

2021

PERSETUJUAN DAN PENGESAHAN

Tesis ini diajukan oleh :

Nama : Elly Firasari
NIM : 14002379
Program Studi : Ilmu Komputer
Fakultas : Teknologi Informasi
Jenjang : Strata Dua (S2)
Konsentrasi : Image Processing
Judul Tesis : “Klasifikasi Citra Kanker Kulit Menggunakan Arsitektur MobileNet”

Telah dipertahankan pada periode 2021-1 dihadapan Dewan Penguji dan diterima sebagai bagian persyaratan yang diperlukan untuk memperoleh gelar Magister Ilmu Komputer (M.Kom) pada Program Studi Ilmu Komputer (S2) Fakultas Teknologi Informasi Universitas Nusa Mandiri.

Jakarta, 12 Agustus 2021

PEMBIMBING TESIS

Pembimbing I : Dr. Dra Dwina Kuswardani, M.Kom



Pembimbing II : Sukmawati Anggraeni Putri, M.kom



DEWAN PENGUJI

Penguji I : Dr. Lindung Parningotan Manik, M.T.I



Penguji II : Dr. Didi Rosiyadi, M.Kom



Penguji III /
Pembimbing I : Dr. Dra Dwina Kuswardani, M.Kom



DAFTAR ISI

HALAMAN SAMPUL	i
HALAMAN PENGESAHAN.....	ii
PENDAHULUAN	1
METODE PENELITIAN.....	2
1. Akuisisi Citra	2
2. Pembagian Dataset	3
3. Klasifikasi dengan Arsitektur MobileNet	4
HASIL PEDAN PEMBAHASAN	5
1. Perbandingan Epoch dan Optimizer Adam.....	5
2. Perbandingan Epoch dan Optimizer RMSprop.....	7
3. Perbandingan Epoch dan Optimizer SGD	9
4. Hasil Perbandingan Akurasi Optimizer	11
5. Hasil Perbandingan Akurasi Dengan Penelitian Sebelumnya	12
PENUTUP	13
1. Kesimpulan	13
2. Saran	13
DAFTAR REFERENSI	13

PENDAHULUAN

Organ tubuh yang paling luar adalah kulit yang berfungsi untuk melindungi tubuh manusia [1] dari sinar *ultraviolet* serta lapisan yang melindungi tulang serta organ dalam manusia [2]. Fungsi kulit mempunyai kepentingan yang sangat besar oleh karena itu sedikit mengalami perubahan atau terjadi masalah pada fungsi kulit maka akan mengganggu bagian lain dari tubuh manusia. Karenakan organ tubuh manusia terluar adalah kulit maka kulit akan sangat rentan mengalami penyakit yang berbahaya salah satunya kanker kulit.

Kanker sendiri merupakan tumbuhnya sel kulit abnormal yang sulit untuk dikendalikan [3] sehingga kanker kulit merupakan kanker yang paling umum dari semua kanker [4]. Penyakit kanker termasuk dalam penyakit yang mematikan di dunia [5]. Setiap tahun banyak kasus kanker terdeteksi dan hampir 50% dari kasus tersebut adalah kanker kulit [6].


Malignant atau melanoma merupakan sejenis kanker pada kulit yang sel-selnya berkembang pada sel melanosit sehingga menghasilkan suatu melamin pada pigmen yang memberi warna pada kulit [7]. Salah satu bentuk dari kanker kulit yang berbahaya adalah Melanoma [8]. Dalam 3 dekade terakhir tingkat kejadian Melanoma semakin tinggi, meskipun kebanyakan orang yang didiagnosis dengan kanker kulit memiliki peluang lebih tinggi untuk sembuh namun tingkat kelangsungan hidup yang didiagnosis kanker kulit jenis Melanoma lebih rendah daripada kanker kulit non-Melanoma [9].

Pencegahan kanker kulit secara dini sangat penting bagi kelompok yang memiliki risiko terhadap kanker kulit [10]. Secara umum dokter kulit (dermatologi) menggunakan Biopsi untuk mendiagnosis kanker kulit [2]. Dimana prosesnya dengan mengambil sampel potongan kecil pada jaringan kulit dan selanjutnya diperiksa di laboratorium. Biaya Biopsi cukup mahal serta dapat melukai atau menggores kulit manusia sehingga perlu memberikan alternatif dalam mendiagnosa kanker kulit yang berbasis komputer yang diharapkan dapat membantu lebih cepat dan akurat dalam mendiagnosa kanker kulit berdasarkan citra berbasis komputer. Penelitian kanker kulit yang dilakukan oleh [11] menggunakan *Convolutional Neural Network* (CNN) digunakan untuk mendeteksi kanker kulit dengan citra 50 lesi jinak dan 47 lesi ganas. Pada penelitian tersebut menggunakan gambar sintesis mendapat hasil yang lebih baik daripada menggunakan database utama [11]. Beberapa penelitian sebelumnya [2] menggunakan 2637 citra untuk data latih dan 660 citra digunakan untuk data uji yang menunjukkan proses klasifikasi berdasarkan fitur tekstur warna yang paling baik pada algoritma KNN.

Mengingat begitu pentingnya penelitian kanker kulit dalam berbagai aspek kehidupan namun permasalahan pengidentifikasian kanker kulit masih terbilang tidak cukup mudah dilakukan, peneliti memandang hal ini perlu diangkat menjadi sebuah topik penelitian. dalam penelitian ini mengusulkan tentang klasifikasi citra kanker kulit menggunakan metode *MobileNet*. Mobilenet dapat digunakan untuk pengenalan objek [12] Kemudian menurut [13] *MobileNets* dapat beroperasi secara efektif di berbagai aplikasi. Arsitektur *MobileNet* digunakan pada *CNN* dikarenakan dapat dapat dipergunakan untuk ponsel dan mengatasi kebutuhan daya komputasi yang berlebih [14]. *MobileNet* juga merupakan kelas jaringan saraf *convolutional* ringan dalam yang ukurannya jauh lebih kecil dan kinerjanya

lebih cepat daripada banyak model populer lainnya [15]. Metode *MobileNet* ini dipakai agar menghilangkan kebutuhan untuk ekstraksi fitur secara manual yang mendapat tugas sebagai pengenalan objek [14]. Kemudian menurut [16] *MobileNet* merupakan salah satu model jaringan yang dikembangkan untuk meningkatkan performa pembelajaran secara real time dengan kondisi hardware yang terbatas tanpa mengurangi jumlah parameter dan mengorbankan akurasi. Penelitian yang diusulkan ini bertujuan untuk mengembangkan sistem klasifikasi deteksi dini terhadap kanker kulit menggunakan metode *MobileNet*.

METODE PENELITIAN



Gambar 1 Metode Penelitian

Gambar 3.1 merupakan gambaran arsitektur umum penelitian klasifikasi menggunakan *Convolutional Neural Network* (CNN) dengan Arsitektur *MobilNet*. Proses awal yaitu melakukan pengumpulan data citra kanker kulit yang terdiri atas data training dan data testing. kemudian data training dibagi menjadi *training* dan *validasi* untuk dilakukan proses pengklasifikasiannya menggunakan *MobileNet*. Hasil akhir dari pengklasifikasian ini akan dianalisis hasil kinerjanya.


1. Akuisisi Citra

Langkah pertama yang dilakukan adalah dengan mengambil dan mengumpulkan citra yang akan diteliti yang bersumber dari dataset online secara online melalui lama www.kaggle.com dengan nama file Skin Cancer: Malignant vs Benign yang diunggah oleh Claudio Fanconi dengan format .jpg, dimensi 224 x 224 piksel. Citra yang diambil dari sumber tersebut adalah sebanyak 3297 citra Skin Cancer yang terdiri data training 2637 yaitu 2 jenis diantaranya Malignant dan Benign

masing masing terdiri dari data *training* kelas malignant 1197 citra, benign 1440 citra sedangkan data *testing* terdiri dari malignant 300 citra dan benign 360 citra.

2. Sampel data Training


Data *training* merupakan data yang digunakan untuk melatih model *MobileNet* yang telah dirancang agar memahami dan membedakan citra kanker kulit yang sudah diberikan indeks sesuai dengan kelasnya. Berikut ini adalah contoh data training dan data testing



Gambar 2. Sampel Dataset Training

Sampel Dataset Testing

Data uji akan digunakan untuk mengukur sejauh mana kelas telah berhasil diklasifikasikan dengan benar. Kumpulan data uji digunakan untuk menguji keakuratan klasifikasi dengan mengevaluasi indeks yang dihasilkan oleh model *MobileNet* yang terlatih.



Gambar 3. Sampel Dataset Tesring


Pembagian Data

Citra yang sudah diambil kemudian dibagi menjadi 3 bagian yaitu data training dengan pembagian 60% dan data testing 20% dan 20% sebagai data validasi. Dengan memisahkan data tersebut bertujuan agar model yang diperoleh memiliki

kemampuan menggeneralisasikan dengan baik dalam proses pengklasifikasian data.

3. Klasifikasi dengan Arsitektur MobileNet

proses klasifikasi citra dengan menggunakan model Transfer Learning MobileNet, Pada tahap ini terdapat dua langkah, langkah pertama merupakan ekstraksi fitur dan langkah kedua merupakan proses klasifikasi. Untuk ekstraksi fitur yang dilakukan adalah mengimport model Mobilenet dari pustaka keras. Model yang diimport menggunakan lapisan konvolusional yang diinisialisasi dengan bobot yang telah ditetapkan dan dilatih sebelumnya menggunakan ImageNet. Selanjutnya, untuk klasifikasi digunakan Global Average Pooling layer dan dense layer dengan SoftMax ditambahkan setelah convolutional layer kemudian pengklasifikasian menggunakan Global Average Pooling (GAP) yang memasukkan nilai rata-rata setiap fitur dan memetakan ke dalam vektor dan menakutkannya kemasukan lapisan SoftMax. Berikut ini merupakan gambaran klasifikasi arsitektur *MobileNet*.



Gambar 4. Arsitektur MobileNet

1. Memasukkan citra input dengan ukuran citra 224x224x3. Nilai 3 merupakan citra yang memiliki tiga buah channel yaitu Red, Green, dan Blue (RGB).
2. Inputan citra diproses melalui lapisan pertama disebut *depthwise convolution*, melakukan penyaringan ringan dengan menerapkan filter konvolusi tunggal per saluran input. Fungsi aktivasi *ReLU* digantikan oleh *ReLU6*, dan normalisasi dilakukan dengan normalisasi *batch*. algoritma (BN), yang mendukung penyesuaian otomatis distribusi data.
3. Lapisan kedua adalah konvolusi 1x1, disebut *pointwise convolution*, yang bertanggung jawab untuk membangun fitur baru melalui komputasi kombinasi linier dari saluran input.
4. Setelah memasuki lapisan ke dua citra akan menuju ke lapisan *Global Average Pooling* yaitu dilakukan proses flatten atau proses mengubah feature map hasil *pooling layer* kedalam bentuk vektor.
5. Pada lapisan klasifikasi menggunakan aktivasi *softmax* untuk menentukan jenis citra termasuk dalam kelas malignant atau benign

HASIL DAN PEMBAHASAN

Dalam mencari akurasi terbaik pada model *MobileNet* diperlukan perbandingan beberapa parameter. Membandingkan beberapa *optimizer* dan epoch akan dilakukan dalam penelitian ini yang merupakan langkah dalam proses pembelajaran model *MobileNet*, dimana jumlah *epoch* yang akan ditentukan dapat mempengaruhi besarnya proses pembelajaran dan akan berhenti pada waktu dan nilai yang ditentukan dengan iterasi. Menurut penelitian sebelumnya, pengoptimalan jumlah *epoch* dipengaruhi oleh beberapa faktor yaitu jumlah data, *learning rate* dan *optimizer*. Tetapi semakin banyak ditambahkan maka bobot jaringan semakin sering diperbarui. Jadi dapat diasumsikan bahwa ukuran waktu akan linier dengan jumlah kumpulan data. Perbedaan jumlah terlalu kecil biasanya akan mendapatkan hasil akurasi yang tidak jauh berbeda. Jadi epoch yang akan digunakan dalam penelitian ini adalah 50, 100 dan 150 dengan tiga *optimizer* yaitu Adam, RMSprop, dan SGD.

1. Perbandingan Epoch dengan Optimizer Adam

Dalam menentukan jumlah *epoch* biasanya tergantung oleh penelitian dengan melihat banyaknya sampel data.. Berikut ini merupakan hasil dari membandingkan *epoch* dengan hasil training menggunakan *optimizer* Adam.

Tabel 1. Perbandingan Epoch dan Optimizer Adam

Epoch	Akurasi	Loss	Runtime
50	0.8576	0.3336	3m
100	0.8652	0.3139	5m
150	0.8561	0.3147	7m

Sumber : Penelitian 2021

Berdasarkan hasil iterasi *epoch* dapat diketahui dengan menggunakan *optimizer* adam menghasilkan akurasi yang tidak jauh berbeda yakni akurasi pada epoch 50 menghasilkan 85.76 % dengan nilai loss 0.3336 , kemudian dengan epoch 100 menghasilkan akurasi 86.52% dengan nilai loss 0.3139, kemudian pada epoch 150 menghasilkan akurasi 85.61 dengan nilai loss 0.3147. sehingga dapat diketahui bahwa dari ketiga *epoch* tersebut mendapat akurasi terbaik pada 100 *epoch*.

Tabel 2. Confussion Matrix Epoch 100 dengan Optimizer Adam

	Malignant	Benign
Pred. Malignant	306	54
Pred. Benign	35	265

Sumber : Penelitian 2021

Berdasarkan tabel 2. menunjukan hasil prediksi dari model terhadap data testing menunjukkan hasil yang lebih baik. pada kasus ini model memprediksi sebanyak 306 citra diprediksi sebagai kelas malignant dan sebanyak 265 citra termasuk kedalam kelas benign, dan ternyata benar citra tersebut adalah kelas benign. kemudian 35 citra sebanyak 54 citra model tidak tepat dalam memprediksi.


Dari hasil confusion matrix yang ditunjukkan pada tabel 2. tersebut dapat disimpulkan bahwa Berdasarkan Tabel 3. menunjukkan hasil prediksi dari model terhadap data testing data baru menunjukkan hasil yang lebih baik. pada kasus ini

Tabel 3. Clsasification Report dari Epoch 100 dan Optimizer Adam

	Precision	Recall	F1-Score	Support
Malignant	0.83	0.88	0.86	300
Benign	0.88	0.84	0.87	360
Accuracy			0.87	660
Macro Avg	0.86	0.87	0.86	660
Wighted Avg	0.87	0.87	0.87	660


Sumber : Penelitian 2021

Tabel 3. menunjukkan hasil dari akurasi *MobileNet* dengan *optimizer* adam dengan nilai *epoch* 100. Pada tabel tersebut Akurasi yang dapat kita lihat bahwa akurasi yang di dapat yaitu sebesar 87% dimana masing-masing kelas malignant mendapat akurasi *F1-Score* 86% sedangkan pada kelas benign mendapatkan akurasi 87%.



Gambar 5. (a) Grafik Akurasi (b) Grafik Loss

Gambar 4.2 menunjukkan grafik performa hasil loss dan *accuracy* dari *optimizer* Adam dengan nilai epoch 100. Jika dilihat pada grafik akurasi training dan validasi terus meningkat namun kurang stabil sedangkan dengan grafik *loss*, nilai *loss* training dan nilai *loss* validasi mengalami penurunan yang stabil.



Gambar 6. Hasil Klasifikasi dengan Optimizer Adam

Model yang dihasilkan dari hasil klasifikasi digunakan untuk memprediksi citra. Citra tersebut terdiri dari kelas malignant dan kelas benign. Berdasarkan Gambar 4.3 hasil klasifikasi meunjukkan terdapat banyak citra yang terprediksi dngan benar dan beberapa prediksi salah. Citra yang terprediksi benar akan berwarna hijau sedangkan citra yang terprediksi salah akan berwarna merah.

2. Perbandingan Epoch dan Optimizer RMSprop

Berikut ini merupakan iterasi dengan epoch 50,100 dan 150 dengan menggunakan optimizer RMSprop.

Tabel 4. Perbandingan Epoch dan Optimizer RMSprop

Epoch	Akurasi	Loss	Runtime
50	0.8606	0.3323	3m
100	0.8327	0.3698	5m
150	0.8652	0.3087	7m

Sumber : Penelitian 2021

Berdasarkan Tabel 4. hasil iterasi epoch dapat diketahui dengan menggunakan optoimizer RMSprop mengasilkan akurasi yang berbeda yakni akurasi pada *epoch* 50 menghasilkan 86.06 % dengan nilai loss 0.3323 , kemudian dengan *epoch* 100 menghasilkan akurasi 83.27% dengan nilai loss 0.3698, kemudian pada *epoch* 150 menghasilkan akurasi 86.52% dengan nilai *loss* 0.3087. sehingga dapat diketahui bahwa dari ketiga *epoch* tersebut mendapat akurasi terbaik pada 150 *epoch*.

Dari hasil confussion matrix yang ditunjukkan pada tabel 4. tersebut dapat jelaskan bahwa berdasarkan tabel 5. menunjukan hasil dari memprediksi model pada data testing data baru menunjukkan hasil yang lebih baik. pada kasus ini

Tabel 5. Confussion Matrix Epoch 150 dengan Optimizer RMSprop

	Malignant	Benign
Pred. Malignant	309	51
Pred. Benign	38	262

Sumber : Penelitian 2021


Berdasarkan tabel 5. menunjukan hasil prediksi dari model terhadap data testing menunjukkan hasil yang lebih baik. pada kasus ini model memprediksi sebanyak 309 citra diprediksi sebagai kelas malignant dan sebanyak 262 citra termasuk kedalam kelas benign, dan ternyata benar citra tersebut adalah kelas benign. kemudian 38 citra sebanyak 51 citra model tidak tepat dalam memprediksi.

Tabel 6. Clsasification Report Epoch 50 dan Optimizer RMSprop

	Precision	Recall	F1-Score	Support
Malignant	0.84	0.87	0.85	300
Benign	0.89	0.86	0.87	360
Accuracy			0.87	660
Macro Avg	0.86	0.87	0.86	660
Wighted Avg	0.87	0.87	0.87	660

Sumber : Penelitian 2021


Tabel 6 menunjukkan hasil dari akurasi model *MobileNet* menggunakan *optimizer* RMSprop dengan nilai epoch 150. Akurasi yang didapatkan yaitu sebesar 87% dimana masing-masing kelas malignant mendapat akurasi *F1-Score* 85% sedangkan pada kelas benign mendapatkan akurasi 87%.



Sumber : Penelitian 2021

Gambar 7. (a) Grafik Akurasi (b) Grafik Loss

Gambar 7. menunjukkan grafik performa hasil *loss* dan *accuracy* dari *optimizer* RMSprop dengan nilai epoch 150. Jika dilihat pada grafik akurasi training dan akurasi validasi terus meningkat sedangkan dengan grafik *loss*, nilai *loss* training dan nilai *loss* validasi mengalami penurunan yang kurang stabil.



Sumber : Penelitian 2021

Gambar 8. Hasil Klasifikasi dengan Optimizer RMSprop

Model yang dihasilkan dari hasil klasifikasi digunakan untuk memprediksi citra. Citra tersebut terdiri dari kelas malignant dan kelas benign. Berdasarkan Gambar 4.5 hasil klasifikasi menunjukkan terdapat banyak citra yang terprediksi dengan benar dan beberapa prediksi salah. Citra yang terprediksi benar akan berwarna hijau sedangkan citra yang terprediksi salah akan berwarna merah.

3. Perbandingan Epoch dengan Optimizer SGD

Berikut ini merupakan iterasi dengan epoch 50,100 dan 150 dengan menggunakan *optimizer* SGD.

Tabel 7. Confussion Matrix Epoch 150 dan Optimizer SGD

Epoch	Akurasi	Loss	Runtime
50	0.8485	0.3694	3m
100	0.8621	0.3417	4m
150	0.8667	0.3277	8m

Sumber : Penelitian 2021

Berdasarkan hasil iterasi epoch dapat diketahui dengan menggunakan *optimizer* SGD menghasilkan akurasi yang berbeda yakni akurasi pada *epoch* 50 menghasilkan 84.85 % dengan nilai loss 0.3694 , kemudian dengan *epoch* 100 menghasilkan akurasi 86.21% dengan nilai loss 0.317, kemudian pada *epoch* 150 menghasilkan akurasi 86.67% dengan nilai loss 0.3277. sehingga dapat diketahui bahwa dari ketiga epoch tersebut mendapat akurasi terbaik pada 150 epoch

Tabel 8. Confussion Matrix Epoch 150 dengan Optimizer SGD

	Malignant	Benign
Pred. Malignant	312	48
Pred. Benign	40	260

Sumber : Penelitian 2021

Berdasarkan tabel 8. menunjukan hasil prediksi dari model terhadap data testing menunjukkan hasil yang lebih baik. pada kasus ini model memprediksi sebanyak 312 citra diprediksi sebagai kelas malignant dan sebanyak 260 citra

termasuk kedalam kelas benign, dan ternyata benar citra tersebut adalah kelas benign. kemudian 40 citra sebanyak 48 citra model tidak tepat dalam memprediksi.


Dari hasil confusion matrix yang ditunjukkan pada Tabel 8. tersebut dapat jelaskan bahwa berdasarkan Tabel 9. menunjukan hasil dari memprediksi model pada data testing data baru menunjukkan hasil yang lebih baik. pada kasus ini

Tabel 9. Clsasification Report Epoch 50 dan Optimizer SGD

	Precision	Recall	F1-Score	Support
Malignant	0.84	0.87	0.86	300
Benign	0.89	0.87	0.88	360
Accuracy			0.87	660
Macro Avg	0.86	0.87	0.87	660
Wighted Avg	0.87	0.87	0.87	660

Sumber : Penelitian 2021

Tabel 9. menunjukan hasil dari akurasi MobileNet menggunakan optimizer SGD dengan nilai epoch 150. Akurasi yang didapatkan yaitu sebesar 87% dimana masing-masing kelas malignant mendapat akurasi F1-Score 86% sedangkan pada kelas benign mendapatkan akurasi 88%.




(a)

(b)

Sumber : Penelitian 2021

Gambar 9. (a) Grafik Akurasi (b) Grafik Loss

Gambar 9. menunjukkan grafik performa hasil loss dan accuracy dari optimizer Adam dengan nilai epoch 150. Jika dilihat pada grafik akurasi training dan akurasi validasi terus meningkat sedangkan dengan grafik training loss dan validasi loss mengalami penurunan yang kurang stabil sehingga model tersebut dapat dikatakan tidak overfitting sehingga model dapat memprediksi dengan baik.



Sumber : Penelitian 2021

Gambar 10. Hasil Kalsifikasi

Model yang dihasilkan dari hasil klasifikasi digunakan untuk memprediksi citra. Citra tersebut terdiri dari kelas malignant dan kelas benign. Berdasarkan Gambar 4.6 hasil klasifikasi meunjukkan terdapat banyak citra yang terprediksi dngan benar dan beberapa prediksi salah. Citra yang terprediksi benar akan berwarna hijau sedangkan citra yang terprediksi salah akan berwarna merah.

4. Hasil Perbandingan Akurasi Optimizer

Berikut ini merupakan perbandingan yangdigunakan dalam menentukan model yang terbaik dari seluruh *optimizer* yang telah dilakukan training. Berikut ini adalah hasil dari masing-masing model *MobileNet* dengan akurasi terbaik berdasarkan optimizer dan epochnya

Tabel 10. Hasil Perbandingan Akurasi

No	Optimizer	Epoch	Akurasi	Loss
1	Adam	100	0.8652	0.3139
2	RMSprop	150	0.8652	0.3087
3	SGD	150	0.8667	0.3277

Sumber : Penelitian 2021

Berdasarkan tabel 10. Dapat diketahui bahwa menggunakan optimizer adam dengan 100 epoch menghasilkan akurasi 86.52% dengan nilai loss 0.3139, kemudian pada optimizer RMSprop dengan menggunakan 150 epoch menghasilkan akurasi sebesar 86.52% dengan nilai loss 0.3087, kemudian pada optimizer SGD mendapatkan hasil akurasi sebesar 86.67% dengan nilai loss 0.3277. maka dapat disimpulkan dengan menggunakan *optmizer* SGD dengan 150 epoch mengasilkan akurasi tertinggi.

5. Hasil Perbandingan Akurasi Dengan Penelitian Sebelumnya

Berikut ini merupakan hasil perbandingan dari penelitian yang telah dilakukan dengan penelitian yang sebelumnya.

Tabel 11. Hasil Perbandingan dengan Penelitian Sebelumnya

No	Penelitian	Tahun	Metode	Akurasi
1	Peneliti	2021	MobileNet	86.67%
2	[2]	2020	KNN	70.61%
3	[11]	2019	CNN	71%.

Sumber : Penelitian 2021

Pada penelitian ini mendapatkan hasil akurasi yang terbaik yaitu 86.67% dengan grafik yang baik dan tepat serta tidak terjadi overfitting. Dibandingkan dengan penelitian yang dilakukan oleh [2] yang masih menggunakan metode knn dengan hasil akurasi 70.61%. Sedangkan penelitian yang dilakukan oleh [11] menggunakan metode Convolutional Neural Network (CNN) dengan metode yang diusulkan Jaringan Adversarial Generatif (GAN) mendapatkan akurasi sebesar 71%. Maka dengan demikian penelitian yang dilakukan oleh peneliti lebih baik daripada penelitian sebelumnya.

KESIMPULAN DAN SARAN

1. Kesimpulan

Berdasarkan pembahasan yang telah dijelaskan pada bab sebelumnya, maka dapat diperoleh kesimpulan mengenai klasifikasi kanker kulit menggunakan arsitektur MobileNet yaitu sebagai berikut:

1. Model *MobileNet* dapat mengidentifikasi jenis citra kanker kulit yaitu jenis malignant dan benign.
2. Dengan menggunakan optimizer Adam dan fungsi aktivasi sigmoid yang diterapkan dalam *arsitektur MobileNet* menghasilkan pengklasifikasian citra kanker kulit dengan iterasi 10 epoch mendapatkan nilai akurasi tertinggi sebesar 86.67% dan nilai loss terendah 0.3277.

2. Saran

Dari berbagai penelitian yang dicapai, terdapat beberapa saran yang ingin penulis sampaikan untuk mengembangkan penelitian diantaranya

1. Penelitian dikembangkan dengan metode lain untuk menghasilkan identifikasi dan akurasi yang lebih baik.
2. Penelitian dikembangkan dengan menggunakan segmentasi atau augmentasi untuk mendapatkan hasil yang lebih baik lagi.
3. Menambahkan macam-macam kategori kanker kulit.

REFERENSI

- [1] E. S. Nugroho and Y. E. Anggraini, "Review Teknik Segmentasi Pada Deteksi Kanker Kulit (Melanoma)," *J. Komput. Terap.*, vol. 4, no. 1, pp. 43–49, 2018.
- [2] F. Firdaus, F. Sthevanie, and K. N. Ramadhani, "Deteksi Kanker Kulit Melanoma Menggunakan Aturan ABCD," *e-Proceeding Eng.*, vol. 5, no. 3, pp. 7642–7648, 2018.

- [3] H. Alquran *et al.*, “The melanoma skin cancer detection and classification using support vector machine,” *2017 IEEE Jordan Conf. Appl. Electr. Eng. Comput. Technol. AEECT 2017*, vol. 2018-Janua, pp. 1–5, 2017, doi: 10.1109/AEECT.2017.8257738.
- [4] S. A. A. Suryantari, A. B. S. Satyarsa, I. G. A. T. Indriani, P. Sudarsa, L. Mas Rusyati, and M. Swastika Adiguna, “Hubungan Tingkat Pengetahuan Dan Sikap Mengenai Paparan Sinar Matahari Dan Kanker Kulit Pada Mahasiswa Kelautan Dan Perikanan Universitas Udayana, Bali,” *Essence Sci. Med. J.*, vol. 17, no. 1, pp. 5–8, 2019.
- [5] M. Faruk, P. Studi, T. Informatika, F. Teknik, and U. I. Lamongan, “Klasifikasi Kanker Kulit Berdasarkan Fitur Tekstur , Fitur Warna Citra Menggunakan SVM dan KNN,” *Telematika*, vol. 13, no. 2, pp. 100–109, 2020.
- [6] P. Sedigh, R. Sadeghian, and M. T. Masouleh, “Generating Synthetic Medical Images by Using GAN to Improve CNN Performance in Skin Cancer Classification,” *ICRoM 2019 - 7th Int. Conf. Robot. Mechatronics*, no. ICRoM, pp. 497–502, 2019, doi: 10.1109/ICRoM48714.2019.9071823.
- [7] I. A. Dewi, “Deteksi Manusia menggunakan Pre-Trained MobileNet untuk Segmentasi Citra Menentukan Bentuk Tubuh,” *MIND J.*, vol. 4, no. 1, pp. 65–79, 2019, doi: 10.26760/mindjournal.v4i1.65-79.
- [8] J. X. Xu, T. C. Lin, T. C. Yu, T. C. Tai, and P. C. Chang, “Acoustic scene classification using reduced mobilenet architecture,” *Proc. - 2018 IEEE Int. Symp. Multimedia, ISM 2018*, pp. 267–270, 2019, doi: 10.1109/ISM.2018.00038.
- [9] Hendriyana and Y. H. Maulana, “Identifikasi Jenis Kayu menggunakan Convolutional Neural Network dengan Arsitektur Mobilenet,” *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 4, no. 1, pp. 70–76, 2020.
- [10] S. Ghoury, C. Sungur, and A. Durdu, “Real-Time Diseases Detection of Grape and Grape Leaves using Faster R-CNN and SSD MobileNet Architectures,” *Int. Conf. Adv. Technol. Comput. Eng. Sci. (ICATCES 2019)*, no. Icatces, pp. 39–44, 2019, [Online]. Available: https://www.researchgate.net/publication/334987612_Real-Time_Diseases_Detection_of_Grape_and_Grape_Leaves_using_Faster_R-CNN_and SSD_MobileNet_Architectures.