

CONVOLUTION NEURAL NETWORK DENGAN DESAIN JARINGAN RESNET SEBAGAI METODE KLASIFIKASI TUMOR KULIT

CONVOLUTION NEURAL NETWORK USING RESNET NETWORK DESIGN AS SKIN TUMOR CLASSIFICATION METHOD

Bagus Mitra Sujatmiko¹⁾, Erni Yudaningtyas²⁾, Panca Mudji Raharjo³⁾

^{1,2,3}Prodi Magister Teknik Elektro, Fakultas Teknik, Universitas Brawijaya Malang

Jl. Veteran, Ketawanggede, Kec. Lowokwaru, Malang

E-mail: ¹*bagusmitrasujatmiko@gmail.com, ²erni@ub.ac.id, ³panca@ub.ac.id

ABSTRAK

Tumor kulit merupakan suatu abnormalitas yang terjadi pada kulit. Tumor tersebut dapat bersifat jinak (benigna) atau ganas (maligna). Sampai saat ini para ahli melakukan diagnosis tumor kulit dengan metode biopsi dengan mengambil sampel potongan kecil pada jaringan kulit dan selanjutnya diperiksa sel - sel nya di laboratorium. Metode tersebut merupakan suatu metode invasif yang memerlukan waktu lama. Pada penelitian ini akan dilakukan identifikasi tumor kulit menggunakan CNN dengan desain jaringan ResNet untuk membantu diagnosis. Metode ini merupakan pengembangan dari *Multilayer Perceptron* (MLP) yang dibuat sedemikian rupa untuk mengolah data dua dimensi. Desain arsitektur menggunakan ResNet untuk mencegah sistem kehilangan banyak informasi selama *training* dilakukan. Hasil yang didapatkan pada penelitian ini dalam penggunaan variasi model arsitektur yaitu ResNet-18, ResNet-50 dan ResNet-101 yaitu waktu yang diperlukan untuk melakukan *training* terhadap 3 jenis kulit menggunakan desain arsitektur jaringan ResNet lebih lama jika dibandingkan *training* terhadap 2 jenis kulit. Penelitian ini menggunakan 1440 data *training* untuk citra benigna, 1197 citra maligna, dan 797 citra normal. Hasil akurasi yang dihasilkan saat klasifikasi 3 jenis kulit berkisar antara 92,60% sampai dengan 92,90% sedangkan untuk 2 jenis kulit berkisar antara 88,03% sampai dengan 89,39%.

Kata kunci: CNN, Klasifikasi, Tumor Kulit Benigna, Tumor Kulit Maligna, ResNet.

ABSTRACT

A skin tumor is an abnormality that occurs in the skin. These tumors can be benign (benign) or malignant (malignant). Until now, experts diagnose skin tumors with the biopsy method by taking small pieces of skin tissue and then examining the cells in the laboratory. This method is an invasive method that requires a long time. In this study, skin tumor identification will be carried out using CNN with a Resnet network design to help diagnostic. This method is a development of the Multilayer Perceptron (MLP) which is made in such a way to process two-dimensional data. The architectural design uses ResNet to prevent the system from losing a lot of information during training. The results obtained in this study using a variety of architectural models, namely ResNet-18, ResNet-50 and ResNet-101, namely the time required to train 3 skin types using the ResNet network architecture design is longer than training for 2 skin types. This study uses 1440 training data for benign images, 1197 malignant images, and 797 normal images. The accuracy results obtained when classifying 3 skin types ranged from 92.60% to 92.90% while for 2 skin types it ranged from 88.03% to 89.39%.

Keywords: CNN, Classification, Benign Skin Tumor, Malignant Skin Tumor, ResNet.

PENDAHULUAN

Tumor merupakan suatu pembengkakan. Tumor menandakan peradangan yang diikuti dengan multiplikasi sel - sel yang tidak terkontrol dan progresif [1]. Tumor dipicu oleh berbagai faktor penyebab yang menyebabkan sel normal mengalami penambahan jumlah dan ukuran yang tidak terkendali [2]. Tumor kulit terdiri dari tumor jinak (benigna) dan tumor ganas (maligna). Tumor jinak merupakan tumor yang berdiferensiasi normal (matang), pertumbuhannya lambat dan ekspansif serta seringkali berkapsul. Tumor ganas (maligna) ialah tumor yang bersifat infiltratif sampai merusak jaringan disekitarnya serta bermetastasis melalui pembuluh darah dan atau pembuluh getah bening. Tumor jinak dapat mendesak jaringan organ sekitarnya, namun biasanya tidak berinfiltrasi merusak jaringan disekitarnya, sehingga bahayanya relatif kecil [2].

Penderita tumor jinak kulit terkadang kurang tanggap melakukan pengobatan. Semakin cepat penyakit tumor jinak diterapi hasil yang didapat akan lebih optimal. Jumlah penderita tumor semakin meningkat beberapa tahun belakangan ini [3]. Indonesia termasuk negara tropis sehingga paparan sinar matahari sangat tinggi terlebih lagi sebagian besar masyarakat banyak melakukan aktivitas yang langsung terpajan sinar matahari, sehingga sangat mempengaruhi proses terjadinya tumor kulit [4]. Menurut WHO, 70.230 orang di dunia meninggal akibat kanker kulit. Penelitian yang dilakukan oleh Wijaya, menunjukkan bahwa terdapat 482 (16,37%) pasien tumor kulit jinak di antara 2.945 pasien baru [3]. Tumor kulit jinak lebih sering terjadi pada perempuan dengan kelompok usia tertinggi adalah 15 – 44 tahun [5].

Sampai saat ini para ahli masih melakukan diagnosis tumor kulit dengan metode biopsi dengan mengambil sampel potongan kecil pada jaringan kulit dan selanjutnya diperiksa sel - sel nya di

laboratorium. Metode tersebut merupakan tindakan invasif yang memerlukan biaya mahal dan waktu lama sehingga perlu adanya alternatif dalam mendiagnosis tumor kulit yang berbasis komputer. Diagnosis tumor kulit dengan pengolahan citra merupakan salah satu metode diagnosis yang cepat dan akurat. Beberapa peneliti telah melakukan riset mengenai penggunaan citra dalam diagnosis tumor kulit dengan berbagai jenis ekstraksi fitur dan metode klasifikasi. Salah satu metode yang dapat digunakan dalam klasifikasi tumor pada kulit adalah *Convolutional Neural Network* (CNN). CNN termasuk dalam jenis *Deep Neural Network* karena kedalaman jaringan yang tinggi dan banyak diaplikasikan pada data citra. Metode ini merupakan pengembangan dari *Multilayer Perceptron* (MLP) yang dibuat sedemikian rupa untuk mengolah data dua dimensi. Arsitektur jaringan pada CNN terdiri dari *input*, proses ekstraksi fitur, proses klasifikasi, dan *output*. Proses ekstraksi dalam CNN terdiri dari beberapa lapisan tersembunyi atau *hidden layer*, yaitu lapisan konvolusi, fungsi aktivasi (ReLU), dan *pooling*. CNN bekerja secara hierarki sehingga *output* pada lapisan konvolusi pertama digunakan sebagai *input* pada lapisan konvolusi selanjutnya. Pada proses klasifikasi terdiri dari *fully - connected* dan fungsi aktivasi (softmax) dengan *output* berupa hasil klasifikasi [6].

Metode CNN merupakan suatu jaringan saraf tiruan. Desain dasar metode ini berdasarkan *convolution* dengan piksel yang berketetapan memiliki pengaruh terhadap keluarannya. Setiap fitur atau setiap neuron pada metode ini berbentuk dua dimensi. Selain itu, metode ini merupakan metode yang berkesinambungan yang artinya keluaran hasil dari *convolution* pertama akan dijadikan masukan untuk *convolution* yang selanjutnya. Kelebihan dari CNN yaitu dapat digunakan untuk data yang berjumlah besar, dapat membentuk model untuk banyaknya lapisan layer yang digunakan, dan merupakan *supervised learning* artinya analisis

dilakukan dengan melatih data *training* sehingga hasil yang didapatkan untuk klasifikasi akan semakin akurat [7]. Penelitian untuk mendeteksi kanker kulit pernah dilakukan oleh Faruk pada tahun 2020 dengan judul Klasifikasi Kanker Kulit Berdasarkan Fitur Tekstur Fitur Warna Citra Menggunakan SVM dan KNN [8]. Hasil akurasi yang didapat yaitu 70.61% untuk klasifikasi menggunakan k-NN dan 69.85% dengan SVM. Berbeda dengan penelitian sebelumnya, pada penelitian ini menggunakan CNN dengan ResNet sebagai model arsitekturnya. ResNet akan mencegah sistem dari kehilangan banyak informasi selama *training* dilakukan. Berdasarkan pertimbangan di atas diharapkan metode CNN dengan menggunakan ResNet dapat memberikan hasil akurasi yang lebih baik dalam mengklasifikasi citra tumor kulit dibandingkan dengan penelitian sebelumnya.

METODE

Prosedur untuk menjawab permasalahan penelitian adalah sebagaimana dijabarkan dalam gambar berikut. Perancangan sistem pada penelitian ini ditunjukkan pada Gambar 1.



Gambar 1. Blok Diagram Sistem Klasifikasi Tumor Kulit

Prosedur penelitian dijelaskan sebagai berikut:

A. Original Image

Data masukan berupa citra digital RGB dengan ukuran 224 x 224 piksel berupa citra kulit benigna dan kulit maligna. Kulit normal berupa citra digital RGB dengan ukuran 1200 x 1600 piksel. Gambar berasal dari ISIC (*International Skin Imaging Collaboration*) dan foto pribadi.

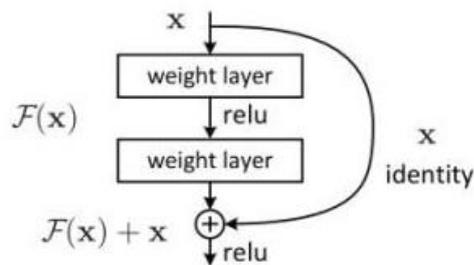
B. ImagePre - Processing

Data masukan kulit normal berupa citra digital RGB dengan ukuran 1200 x 1600 piksel dikonversikan kedalam ukuran 224 x 224 piksel untuk menyamakan ukuran data citra kulit benigna dan maligna. Pembagian data masukan dibagi menjadi dua bagian yaitu data *training* sejumlah 80% dan data validasi sejumlah 20% dari total data masukan.

C. Arsitektur desain CNN dengan menggunakan ResNet

ResNet adalah kepanjangan dari *Residual Network* [9]. Arsitektur desain CNN ini diusulkan oleh He, dkk [10]. Pada tahun 2015 arsitektur ini muncul untuk mengatasi permasalahan pada pelatihan *deep learning* yang memakan waktu yang cukup lama dan terbatas pada jumlah lapisan tertentu [11]. Ciri khas pada arsitektur ini dengan menerapkan *skip connection* atau *shortcut*.

Fungsi dari *skip connection* atau *shortcut* tersebut adalah agar pelatihan tidak jenuh dan menghindari kesalahan yang cukup tinggi. *Skip connection* atau *shortcut* pada desain jaringan terdapat di lapisan identitas atau *identity block* ResNet yang dapat ditunjukkan pada Gambar 2.

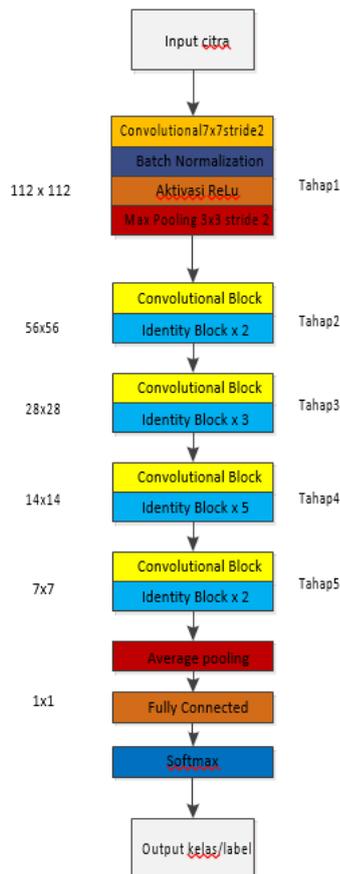


Gambar 2. Identity Block ResNet

ResNet memiliki berbagai jenis arsitektur yang dibedakan berdasarkan jumlah layer yang digunakan. Jumlah layer yang digunakan dalam arsitektur ResNet yaitu mulai dari 18 layer, 34 layer, 50 layer, 101 layer dan 152 layer [5]. Dua lapisan awal dari arsitektur ResNet menyerupai GoogleNet dengan melakukan *convolution* 7×7 dan max pooling berukuran 3×3 .

Kelebihan model ResNet dibandingkan dengan model arsitektur CNN yang lain adalah kinerja dari model ini tidak menurun walaupun arsitektur nya semakin dalam. Selain itu, perhitungan komputasi yang dilakukan lebih ringan dan kemampuan untuk melatih jaringan yang lebih baik [12].

Pada penelitian ini ResNet yang digunakan adalah ResNet-8, ResNet-50 dan ResNet-101. Berikut adalah ilustrasi proses metode CNN dengan ResNet-50. Proses arsitektur ResNet-50 ditunjukkan pada Gambar 3.



Gambar 3. Blok Diagram Model ResNet-50

Proses secara detail dijelaskan sebagai berikut :

1. Data citra kulit berukuran 224×224 piksel sebagai data masukan.
2. Data masukan diproses dengan menambahkan *zero padding* berukuran 3 [13].

Tahap 1

1. Melakukan operasi *convolutional* dengan filter 7×7 dengan 64 *channel* dengan *stride* = 2.
2. Melakukan operasi fungsi *batch normalization*.
3. Menambahkan fungsi aktivasi menggunakan ReLu.
4. Melakukan operasi fungsi maxpooling.
5. 3×3 dengan *stride* = 2.
6. *Output* dari proses tahapan ini menghasilkan ukuran citra 112×112 piksel.

Tahap 2

1. Melakukan operasi *identity block* dengan *filter* 1×1 , 3×3 dan 1×1 dengan *channel* 64, 64 dan 256 serta *stride* = 1 yang dilakukan perulangan sebanyak 2 kali.
2. *Output* dari proses tahapan ini menghasilkan ukuran citra 56×56 piksel.

Tahap 3

1. Melakukan operasi *convolusi block* dengan *filter* 1×1 , 3×3 dan 1×1 dengan *channel* 128, 128 dan 512.
2. Melakukan operasi *identity block* dengan *filter* 1×1 , 3×3 dan 1×1 dengan *channel* 128, 128 dan 512 yang dilakukan perulangan sebanyak 3 kali.
3. *Output* dari proses tahapan ini menghasilkan ukuran citra 28×28 piksel.

Tahap 4

1. Melakukan operasi *convolusi block* dengan *filter* 1×1 , 3×3 dan 1×1 dengan *channel* 256, 256 dan 1024.
2. Melakukan operasi *identity block* dengan *filter* 1×1 , 3×3 dan 1×1 dengan *channel* 256, 256 dan 1024 yang dilakukan perulangan

- sebanyak 5 kali.
3. *Output* dari proses tahapan ini menghasilkan ukuran citra 14 x 14 piksel.

Tahap 5

1. Melakukan operasi *convolution block* dengan filter 1 x 1, 3 x 3 dan 1 x 1 dengan channel 512, 512 dan 2048.
2. Melakukan operasi *identity block* dengan filter 1 x 1, 3 x 3 dan 1 x 1 dengan channel 512, 512 dan 2048 yang dilakukan perulangan sebanyak 2 kali.
3. *Output* dari proses tahapan ini menghasilkan ukuran citra 7 x 7 piksel.

Setelah proses ekstraksi fitur selesai, kemudian hasil *output convolusi* tersebut diproses dengan operasi *average pooling* [14]. Selanjutnya melakukan proses *flatten* sehingga mendapatkan *output array* satu dimensi. *Output* dari operasi *flatten* akan diproses menggunakan *fully connected layer* dan dihasilkan hasil akhir. Perbedaan hasil akhir dengan hasil yang diinginkan ini akan membuat perubahan pada setiap bobot pada jaringan *neural network* dengan algoritma *backpropagation*. Setelah mendapatkan bobot dengan perubahan hasil akhir yang kecil, maka selanjutnya dilakukan proses klasifikasi dengan metode *softmax*. Hasil dari proses klasifikasi akan dihasilkan berupa kelas data.

D. Pengujian Data *Testing*

Hasil dari arsitek design CNN berupa *network/jaringan*, jaringan ini digunakan untuk menguji *image data testing* [15]. Dalam pengujian ini data uji maligna berjumlah 360 gambar citra dengan ukuran 224 x 224 piksel. Data uji benigna berjumlah 300 gambar citra dengan ukuran 224 x 224 piksel. Data uji normal berjumlah 331 gambar citra dengan ukuran 224 x 224 piksel.

E. Pengujian

Setelah semua proses dilakukan, maka untuk mengetahui sejauh mana performanya perlu dilakukan pengujian. Pengujian dilakukan menggunakan

metode ROC untuk mendapatkan nilai *sensitivity*, *specificity*, *accuracy* data dan menggambarkan grafik kurva ROC.

Hasil pengujian ini dari masing masing metode klasifikasi nantinya akan dibandingkan.

$$Sensitivity = \frac{TP}{TP+FN} \times 100\% \quad (1)$$

$$Specificity = \frac{TN}{TN+FP} \times 100\% \quad (2)$$

$$Accuracy = \frac{TP+TN}{TP+TN+FP+FN} \times 100\% \quad (3)$$

Keterangan:

TP (*True Positive*) = Jumlah tumor maligna dan benigna yang terdeteksi tumor maligna dan benigna.

TN (*True Negative*) = Jumlah kulit normal yang terdeteksinormal

FP (*False Positive*) = Jumlah tumor maligna dan benigna yang terdeteksi kulit normal.

FN (*False Negative*) = Jumlah kulit normal yang terdeteksi tumor maligna dan benigna.

HASIL DAN PEMBAHASAN

A. *Preprocessing* Citra

Pada tahap *preprocessing* ukuran piksel yang berbeda – beda pada setiap citra akan disamakan satu sama lain. Proses ini berlaku baik pada data *training* maupun data *testing*. Penelitian ini menggunakan dua sumber data berbeda yaitu dari ISIC dan dari data pribadi. Dua sumber tersebut memiliki resolusi yang berbeda. Citra yang berasal dari data pribadi memiliki resolusi sebesar 1200 x 1600 piksel sedangkan citra yang bersumber dari ISIC memiliki resolusi 224 x 224 piksel. Ukuran dimensi citra yang digunakan dalam penelitian ini harus diseragamkan menjadi 224 x 224 piksel. Resolusi citra yang berasal dari data pribadi akan disesuaikan dengan resolusi citra yang berasal dari data ISIC sehingga keseluruhan citra akan memiliki resolusi 224 x 224 piksel. Gambar 4, 5, dan 6 menunjukkan kulit benigna, maligna, dan normal.



Gambar 4. Maligna



Gambar 5. Normal

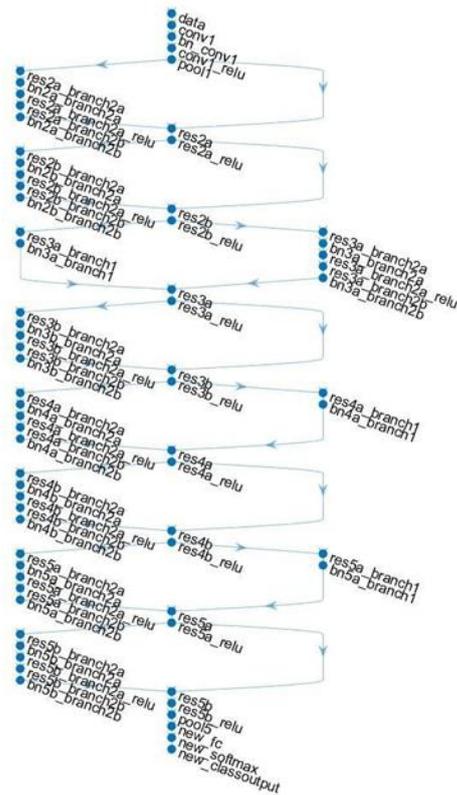
Ukuran dimensi masukan ini juga dilakukan secara seragam agar semua dimensi sama untuk memudahkan proses operasi *convolusi*, ReLu, dan pooling. Penyeragaman ukuran dimensi dilakukan agar input citra tidak memiliki dimensi yang berbeda - beda. Pengoperasian serangkaian operasi konvolusi, ReLu, dan pooling dengan input yang memiliki dimensi piksel yang berbeda akan menghasilkan hasil parameter yang berbeda-beda sebagai hasil *output* dari *Feature ekstraksi Network* yang akan digunakan sebagai *input Clasiffier Network*. Hal tersebut menjadikan parameter satu citra dengan citra yang lain berbeda sehingga tidak dapat dilakukan proses deep learning sebagai satu kesatuan sistem atau terbentuknya jaringan yang diharapkan.

Penelitian ini menggunakan total keseluruhan 4425 data citra yang terbagi menjadi dua kelompok besar yaitu

kelompok data *training* dan kelompok data *testing*. Masing - masing kelompok dikategorikan menjadi tiga klasifikasi yaitu benigna, maligna, dan normal. Pada kelompok data *training* terdapat 1440 data citra benigna, 1197 data citra maligna, dan 797 data citra normal. Pada kelompok data *testing* terdapat 360 data citra benigna, 300 data citra maligna, dan 331 data citra normal.

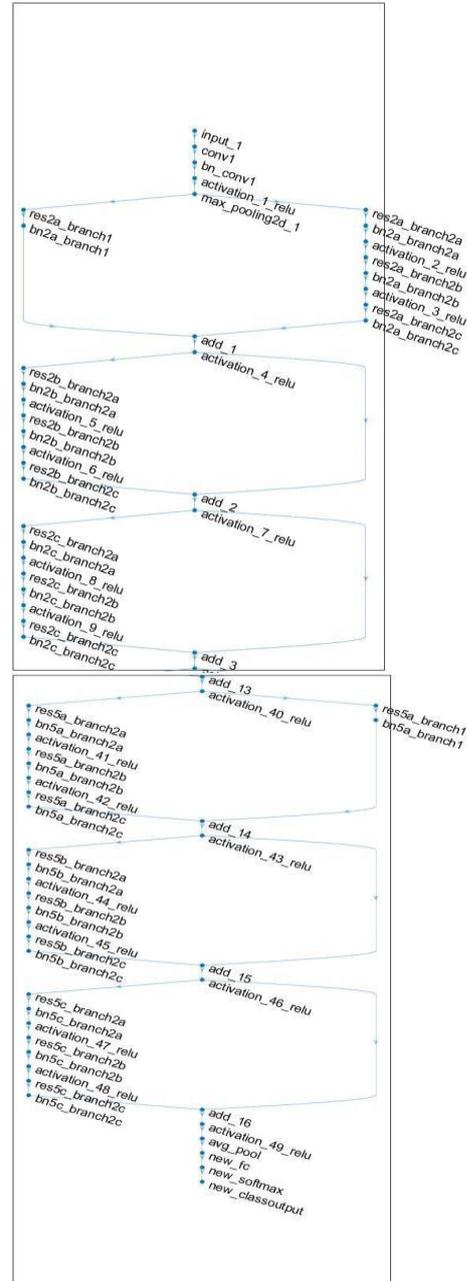
B. Pembuatan Model *Convolutional neural Network*

Model *convolusi* yang digunakan yaitu tipe model jaringan *pre-trained*. Model jaringan ini telah terdapat di Matlab namun dilakukan penggantian pada 3 layer terakhir. Layer tersebut diganti dengan sesuai dengan *output* kategori sesuai penelitian. Jaringan *pre-trained* yang digunakan pada penelitian ini adalah desain arsitektur ResNet-18, ResNet50, dan ResNet-101. Ketiga arsitektur tersebut memiliki perbedaan kedalaman jaringan dimana ResNet-18 memiliki kedalaman 71 layer, sementara ResNet-50 memiliki kedalaman 177 layer, dan ResNet-101 memiliki kedalaman 347 layer. Gambar 7 hingga 9 menunjukkan model jaringan ResNet yang masing-masing berurutan menunjukkan arsitektur jaringan ResNet-18, ResNet-50 dan ResNet-101.



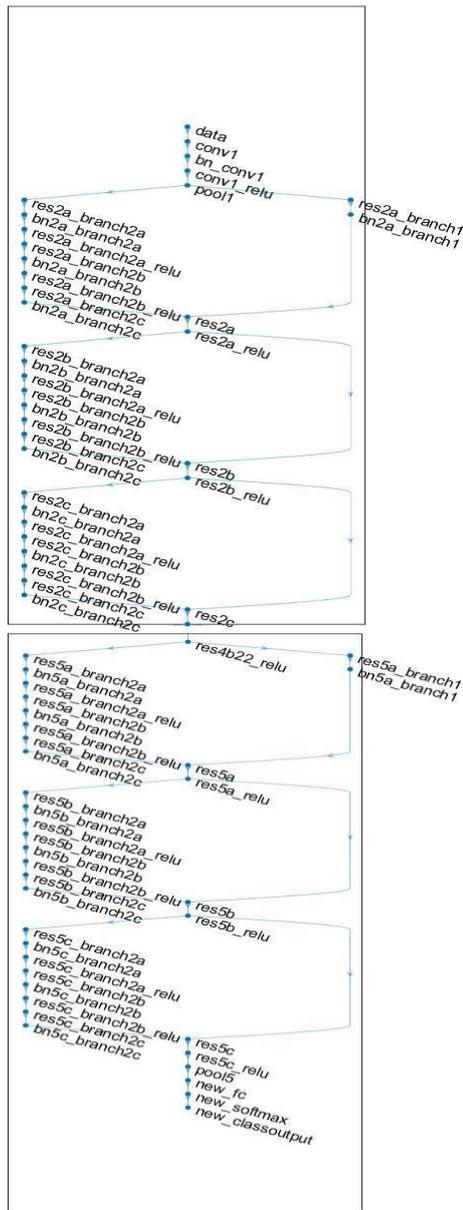
Gambar 6. Desain Arsitektur ResNet-18

ResNet-18 terdiri dari 71 layer yang diawali *input_1* hingga *new_classoutput* yang ditunjukkan pada Gambar 6.



Gambar 7. Desain Arsitektur ResNet-50.

ResNet-50 terdiri dari 177 layer yang diawali *input_1* hingga *new class output* yang ditunjukkan pada Gambar 7.



Gambar 8. Desain Arsitektur ResNet-101.

ResNet-101 terdiri dari 347 layer yang diawali *input_1* hingga *new_classoutput* yang ditunjukkan pada Gambar 8.

Setelah arsitektur model disusun, kemudian dilakukan persiapan proses pelatihan terhadap model yang digunakan. Proses pelatihan terhadap model ini dipersiapkan untuk mengikuti parameter pelatihan yang ditunjukkan pada Tabel 1.

Tabel 1. Parameter

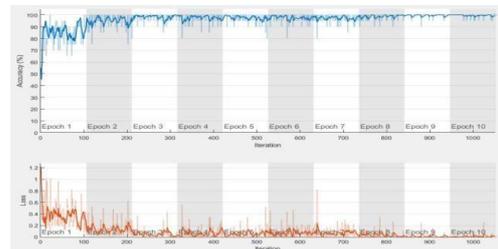
No	Parameter	Nilai
1	Optimizer	Adam
2	loss Function	Crossentropy

No	Parameter	Nilai
3	Train split	80 %
4	Validation split	20%
5	Epoch	10
6	Mini Batch	20
7	Learning Rate	0,0001

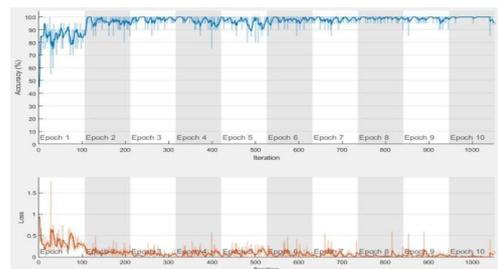
Tabel 1 menunjukkan parameter yang digunakan pada proses pelatihan.

C. Pelatihan dan Hasil Model Arsitektur ResNet-18, ResNet-50 dan ResNet 101 Dengan Dua Jenis Kulit.

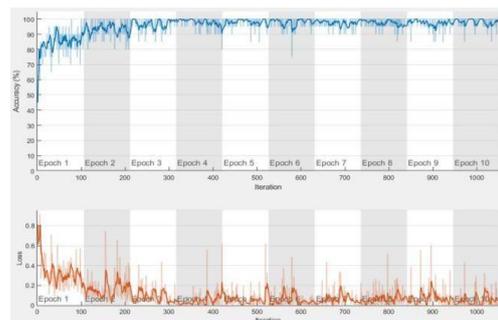
Gambar 9, 10, dan 11 menunjukkan grafik akurasi dan *error* pada *training* ResNet-18, 50, dan 101 dengan 2 jenis kulit.



Gambar 9. Grafik Akurasi dan Error Training ResNet-18



Gambar 10. Grafik Akurasi dan Error Training ResNet-50



Gambar 11. Grafik Akurasi dan Error Training ResNet-101

Tabel 2. Hasil *Training* Jaringan Variasi Desain Jaringan ResNet untuk 2 Jenis Kulit.

	Waktu (detik)	Error	Accurac y
ResNet-18	13.164	0,0068	100 %
ResNet-50	33.599	0,1065	95%.
ResNet-101	57.891	0,0359	100%.

Pada tabel 2 ditunjukkan hasil dari training variasi desain jaringan ResNet untuk kulit benigna dan maligna.

Pengujian ResNet-18 untuk mengklasifikasi 2 jenis kulit yaitu benigna dan maligna didapatkan akurasi validasi data *training* dengan nilai 86,5 % dengan *loss* validasi terakhir 0,0068. *Progress training* dengan menggunakan ResNet-18 menghabiskan waktu 219 menit 24 detik. Nilai akurasi yang didapatkan menggunakan ResNet-18 untuk menguji data testing adalah 88,03% dengan nilai sensitifitas 86,12 % dan nilai spesifikasi 90,77 %. *Elapsed time* menggunakan jaringan ini yaitu 0,41689 detik dalam 1 proses pengolahan 1 buah citra.

Pengujian ResNet-50 untuk mengklasifikasi 2 jenis kulit yaitu benigna dan maligna didapatkan akurasi validasi data *training* nilai 88,4 % dengan *loss* validasi terakhir 0,1064. *Progress training* dengan menggunakan ResNet-50 menghabiskan waktu 559 menit 59 detik. Nilai akurasi yang didapatkan menggunakan ResNet-50 untuk menguji data testing adalah 88,4848 % dengan nilai sensitifitas 92,51%, dan nilai spesifikasi 84,35%. *Elapsed time* menggunakan jaringan ini yaitu 0,7429 detik dalam 1 proses pengolahan 1 buah citra.

Pengujian ResNet-101 untuk mengklasifikasi 2 jenis kulit yaitu benigna dan maligna didapatkan akurasi validasi data *training* nilai 87,1 % dengan *loss* validasi terakhir 0,0358. *Progress training* dengan menggunakan ResNet-101 menghabiskan waktu 964 menit 51 detik. Nilai akurasi yang didapatkan menggunakan ResNet-101 untuk menguji data *testing* adalah 89,3939 % dengan nilai sensitifitas 95,03 % dan nilai spesifikasi 86,58 %. *Elapsed time* menggunakan jaringan ini yaitu 1.364

detik dalam 1 proses pengolahan 1 buah citra. Hasil menggunakan ketiga desain jaringan dalam menggunakan dua jenis kulit terangkum dalam tabel 3.

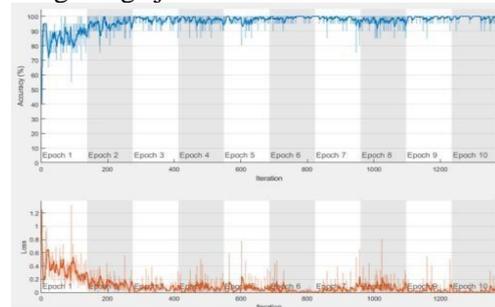
Tabel 3. Hasil menggunakan variasi ResNet- dua jenis kulit.

	Akur si data valida si	Akuras i Data testing	Sensitifitas	Specif i tas	Elape d Time (detik)
ResN	86,5	88,03	86,12	90,77	0,42
ResN	88,4	88,48	92,51	84,35	0,74
ResN et101	87,1	89,39	95,03	86,58	1,36

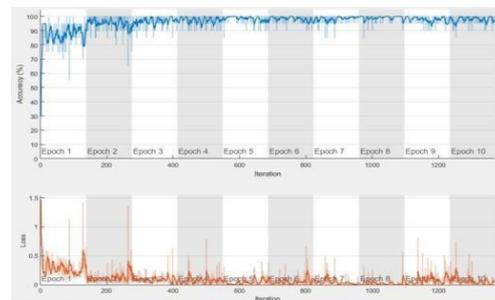
Pada tabel 3 ditunjukkan hasil dari training variasi desain jaringan ResNet untuk kulit benigna dan maligna.

D. Hasil Pelatihan Model Arsitektur ReNet-18, ResNet-50, dan ResNet-101 dengan tiga jenis kulit.

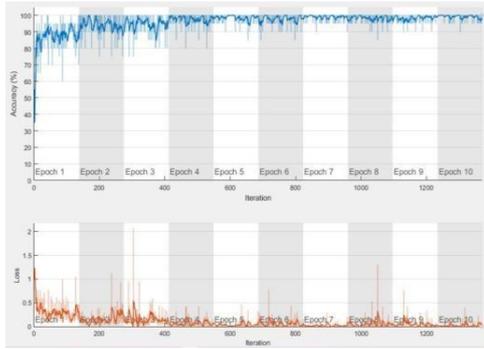
Gambar 12, 13, dan 14 menunjukkan grafik akurasi dan *error* pada *training* ResNet 18, 50, dan 101 dengan tiga jenis kulit.



Gambar 12. Grafik Akurasi dan *Error Training* ResNet-18



Gambar 13. Grafik Akurasi dan *Error Training* ResNet-50



Gambar 14. Grafik Akurasi dan Error Training ResNet-101

Tabel 4. Hasil Training Jaringan Variasi Desain Jaringan ResNet untuk 3 Jenis Kulit.

	Waktu (detik)	Error	Accuracy
ResNet-18	20.192	0,0006	100 %
ResNet-50	39.945	0,0534	95%.
ResNet-101	69.616	0,0002	100%.

Pada tabel 4 ditunjukkan hasil dari *training* variasi desain jaringan ResNet untuk kulit benigna, maligna, dan normal.

Pengujian ResNet-18 untuk mengklasifikasi 3 jenis kulit yaitu benigna, maligna dan normal didapatkan akurasi validasi data *training* dengan nilai 91,8% dengan *loss* validasi terakhir 0,0006. Progress *training* dengan menggunakan ResNet-18 menghabiskan waktu 20.192 detik. Nilai akurasi yang didapatkan menggunakan ResNet-18 untuk menguji data *testing* adalah 92,9% dengan nilai sensitifitas 96,2% dan nilai spesifikasi 96,6%. *Elapsed time* menggunakan jaringan ini yaitu 0.6006 detik dalam 1 proses pengolahan 1 buah citra.

Pengujian ResNet-50 untuk mengklasifikasi 3 jenis kulit yaitu yaitu benigna, maligna dan normal didapatkan akurasi validasi data *training* nilai 91.8% dengan *loss training* terakhir 0.0534. Progress *training* dengan menggunakan ResNet-50 menghabiskan waktu 39.945 detik. Nilai akurasi yang didapatkan menggunakan ResNet-50 untuk menguji data *testing* adalah 92,8% dengan nilai sensitifitas 97% dan nilai spesifitas 96,2%. *Elapsed time* menggunakan

jaringan ini yaitu 0,753 detik dalam 1 proses pengolahan 1 buah citra.

Pengujian ResNet-101 untuk mengklasifikasi 3 jenis kulit yaitu benigna dan maligna didapatkan akurasi validasi data *training* nilai 87,1% dengan *loss* validasi terakhir 0,0002. Progress *training* dengan menggunakan ResNet-101 menghabiskan waktu 69.616 detik. Nilai akurasi yang didapatkan menggunakan ResNet-101 untuk menguji data *testing* adalah 89.3939% dengan nilai sensitifitas 97,7% dan nilai spesifikasi 95%. *Elapsed time* menggunakan jaringan ini yaitu 1.4306 detik dalam 1 proses pengolahan 1 buah citra. Hasil menggunakan ketiga desain jaringan dalam menggunakan tiga jenis kulit terangkum dalam tabel 6.

Tabel 5. Hasil Variasi ResNet 3 Jenis Kulit

	Time (detik) training	akurasi	Sensitifitas	spesifitas	Elapsed Time (detik)
ResNet 18	20.192	92,90	96,2	06,6	0,60
ResNet 50	39.945	92,80	97	96,2	0,75
ResNet 101	69.616	92,60	97,7	95	1,43

Tabel 5 menunjukkan hasil variasi dari ResNet-18, ResNet-50, dan ResNet-101 dalam mengklasifikasikan jenis kulit benigna, maligna, dan normal.

SIMPULAN

Berdasarkan penelitian yang dilakukan, CNN menunjukkan nilai akurasi yang lebih baik dalam klasifikasi tumor kulit jika dibandingkan dengan metode sebelumnya yang akurasinya belum mencapai 80%. Selain itu semakin dalam layer neuron yang digunakan maka hasil akurasi akan semakin baik. Hasil akurasi dengan menggunakan 2 kelas di dapatkan akurasi terbaik menggunakan ResNet-10 dikarenakan menggunakan layer yang dalam dan banyak. Pada klasifikasi 3 kelas akurasi ketiganya memiliki nilai yang hampir sama yaitu pada kisaran angka 92%. Hal tersebut

dikarenakan hasil akurasi dari kulit normal sendiri hampir mendekati 100% sehingga secara kumulatif ketiganya memiliki nilai yang sama.

Hasil klasifikasi tumor kulit dengan menggunakan CNN dengan 2 varian desain arsitektur ResNet menghasilkan akurasi antara 88,03% sampai dengan 89,39% untuk pengklasteran menjadi 2 klaster (tumor jinak dan tumor ganas) dengan waktu training antara 13.161 detik sampai dengan 57.891 detik. Pengklasteran menjadi 3 klaster (tumor jinak, tumor ganas, dan normal) menghasilkan akurasi antara 92,6% sampai dengan 92,90% dengan waktu *training* antara 20.192 detik sampai dengan 69.616 detik. Klasifikasi tumor kulit dengan menggunakan CNN dengan varian desain arsitektur ResNet dapat mengklasifikasi tumor kulit jinak (benigna), ganas (maligna), dan kulit normal dengan akurasi lebih dari 90%.

SARAN

Bagi peneliti selanjutnya dapat dipertimbangkan untuk memperluas klasifikasi masing-masing tumor mengingat masih terdapat beberapa subklasifikasi pada tumor jinak dan ganas.

Bagi peneliti lain dapat ditambahkan *integrated device* misalnya *arduino* atau *raspberry pi* untuk membantu diagnostik agar dapat mengklasifikasi tumor kulit agar semakin cepat dan minimal invasif.

UCAPAN TERIMA KASIH

Puji syukur kehadirat Allah SWT yang telah memberikan kesehatan, kekuatan, dan kelancaran selama penulisan penelitian ini. Nabi Muhammad SAW, sebagai Tuhan yang telah memberikan tauladan yang ideal bagi umatnya. Kedua orang tua yang selalu memberika doa, kasih sayang, dorongan, dan dukungan moril dan materilnya. Kepada pembimbing saya yang telah membimbing saya dalam mengembangkan jurnal penelitian saya, dan kepada semua pihak yang telah

membantu saya dalam menyelesaikan penelitian saya.

DAFTAR PUSTAKA

- [1] Dorland, Kamus Kedokteran Dorland, 29th ed. EGC, 2002.
- [2] Desen, Buku Ajar Onkologi Klinik. Edisi 2. Jakarta: Balai Penerbit FKUI; 2008.p.3. 5. Jakarta: Balai Penerbit FKUI, 2008.
- [3] A. Djuanda, Ilmu Penyakit Kulit dan Kelamin, 5th ed. Jakarta: Balai PenerbitFKUI.
- [4] R. S. Siregar, "Tumor jinak kulit," Saripati penyakit kulit, p. 269, 2014.
- [5] G. A. Gefilem, "Profil Tumor Jinak Kulit Di Poliklinik Kulit Dan Kelamin Rsup Prof. Dr. R. D Kandou Manado Periode 2009-2011," e-CliniC, vol. 1, no. 1, 2013, doi: 10.35790/ecl.1.1.2013.3291.
- [6] S. R. Suartika E. P, I Wayan, Wijaya Arya Yudhi, "Klasifikasi Citra Menggunakan Convolutional Neural Network (Cnn) Pada Caltech 101," J. Tek. ITS, vol. 5, no. 1, p. 76, 2016, [Online]. Available: <http://repository.its.ac.id/48842/>
- [7] J.Kim, O.Sangjun, Y.Kim, and M. Lee, "Convolutional Neural Network with Biologically Inspired Retinal Structure," Procedia Comput. Sci., vol. 88, pp. 145–154, 2016, doi: 10.1016/j.procs.2016.07.418.
- [8] M. Faruk, P. Studi, T. Informatika, F. Teknik, and U. I. Lamongan, "Telematika Klasifikasi Kanker Kulit Berdasarkan Fitur Tekstur, Fitur Warna Citra Menggunakan SVM dan KNN," Telematika, vol. 13, no. 2, pp. 100–109, 2020.
- [9] K. He, X. Zhang, S. Ren, and J. Sun, "Deep residual learning for image recognition," Proc. IEEE

- Comput. Soc. Conf. Comput. Vis. Pattern Recognit., vol. 2016-Decem, pp. 770–778, 2016, doi: 10.1109/CVPR.2016.90.
- [10] A.L.Katole, K.P.Yellapragada, A K. Bedi, S. S. Kalra, and M. Siva Chaitanya, “Hierarchical Deep Learning Architecture for 10K Objects Classification,” no. December, pp. 77–93, 2015, doi: 10.5121/csit.2015.51408.
- [11] B. Zhang, C. Li, and N. Lin, 9. Deep learning and neural networks. 2020. doi: 10.1515/9783110595567-010.
- [12] S. Albelwi and A. Mahmood, “A framework for designing the architectures of deep Convolutional Neural Networks,” Entropy, vol. 19, no. 6, 2017, doi: 10.3390/e19060242.
- [13] E. N. Arrofiqoh and H. Harintaka, “Implementasi Metode Convolutional Neural Network Untuk Klasifikasi Tanaman Pada Citra Resolusi Tinggi,” Geomatika, vol. 24, no. 2, p. 61, 2018, doi: 10.24895/jig.2018.24-2.810.
- [14] M. B. Bejiga, A. Zeggada, A. Nouffidj, and F. Melgani, “A convolutional neural network approach for assisting avalanche search and rescue operations with UAV imagery,” Remote Sens., vol. 9, no. 2, 2017, doi: 10.3390/rs9020100.
- [15] D. Sarwinda, R. H. Paradisa, A. Bustamam, and P. Anggia, “Deep Learning in Image Classification using Residual Network (ResNet) Variants for Detection of Colorectal Cancer,” Procedia Comput. Sci., vol. 179, no. 2019, pp. 423–431, 2021, doi: 10.1016/j.procs.2021.01.025.