

Modifikasi *Convolutional Neural Network* Arsitektur GoogLeNet dengan *Dull Razor Filtering* untuk Klasifikasi Kanker Kulit

Sofia Sa'idah¹, I Putu Yowan Nugraha Suparta², Efri Suhartono³

Intisari—Kulit merupakan organ luar terluas yang menutupi tubuh manusia. Akibat intensitas tinggi paparan lingkungan luar, kulit dapat mengalami berbagai masalah kesehatan, salah satunya adalah kanker kulit. Deteksi dini dibutuhkan agar penanganan lebih lanjut kepada pasien dapat segera dilakukan. Pemanfaatan *artificial intelligence (AI)-based solution* pada pengolahan citra kanker kulit dapat digunakan untuk mendeteksi adanya potensi kanker kulit. Pada makalah ini, dilakukan klasifikasi jenis kanker kulit jinak dan ganas dengan memanfaatkan metode *convolutional neural network (CNN)* arsitektur GoogLeNet. Arsitektur GoogLeNet memiliki keunggulan dengan adanya *inception module* yang memungkinkan proses konvolusi dan *pooling* berjalan secara paralel, yang dapat memperpendek waktu komputasi, sehingga mempercepat proses klasifikasi tanpa mengurangi akurasi sistem. Penelitian ini terdiri atas beberapa tahapan, dimulai dengan akuisi data sejumlah enam ratus data citra kanker kulit yang diperoleh dari situs *Kaggle.com*, kemudian dilakukan penyeragaman ukuran masukan serta pemanfaatan *dull razor filtering* untuk mengurangi derau citra masukan akibat rambut-rambut halus yang tumbuh di sepanjang epidermis kulit. Setelah proses *preprocessing* selesai dilakukan, arsitektur GoogLeNet memproses masukan citra, lalu mengklasifikasikan masukan ke dalam kategori kanker kulit jinak (*benign*) atau kanker kulit ganas (*malignant*). Kinerja sistem kemudian diuji dengan parameter kinerja, seperti presisi, *recall*, dan *f-1 score*, serta dibandingkan dengan metode serupa. Sistem berhasil memperoleh hasil yang memuaskan, di antaranya adalah akurasi 97,73% dan *loss* 1,7063. Sementara itu, untuk parameter presisi, *recall*, dan *f-1 score*, masing-masing diperoleh nilai rata-rata 0,98. Kinerja sistem yang diusulkan berhasil mendapatkan akurasi yang lebih baik dibandingkan dengan penelitian terdahulu dengan penggunaan *dataset* yang jauh lebih sedikit. Hasil pengujian ini menunjukkan bahwa metode CNN mampu melakukan deteksi dan klasifikasi pada kanker kulit secara akurat, sehingga diharapkan metode ini dapat membantu pekerja medis dalam melakukan diagnosis kepada masyarakat luas.

Kata Kunci— Akurasi, CNN, *F-1 score*, GoogLeNet, Kanker Kulit, *Loss*, *Precision*, *Recall*.

I. PENDAHULUAN

Kulit adalah organ terluas yang menutupi tubuh manusia [1]. Kulit berperan sebagai garda pertahanan tubuh terhadap

patogen atau zat-zat yang dapat membahayakan organ tubuh di dalam. Karena letaknya di bagian paling luar tubuh, kulit sering mengalami masalah kesehatan, salah satunya adalah kanker kulit. Kanker kulit adalah benjolan atau penumbuhan jaringan kulit yang berlebihan dan tidak teratur, sehingga merusak jaringan di sekitarnya [2]. Di Indonesia, kanker kulit menempati urutan ketiga setelah kanker rahim dan kanker payudara sebagai kanker yang paling banyak terjadi [2]. Kanker kulit terbagi dalam kelas kanker kulit jinak (*benign*) dan kanker kulit ganas (*malignant*). Sebanyak 7,9% dari total kasus kanker kulit di Indonesia tergolong ganas (*melanoma maligna*) sebagai akibat dari sel kanker yang invasif, sehingga menyebabkan penyakit ini memiliki tingkat kematian yang tinggi. Walau kasus kanker kulit, terkhusus pada kanker kulit ganas, tergolong rendah, deteksi dini kanker kulit tetap dibutuhkan agar pasien dapat segera mendapatkan penanganan medis yang tepat. *Artificial intelligence (AI)-based solution*, melalui *deep learning* pada olah citra, dapat menjadi solusi yang dibutuhkan untuk membantu pekerja medis dalam melakukan pemeriksaan dan klasifikasi jenis kanker. Hal ini disebabkan oleh kemampuan model ini yang dapat mengenali pola melalui ekstraksi fitur citra yang dimiliki secara akurat. Akurasi yang diperoleh ketika menggunakan model ini juga tergolong tinggi, sehingga potensi kanker kulit pada pasien dapat segera diketahui dan penanganan lanjutan terhadap kanker kulit yang diderita dapat segera diberikan guna mencegah memburuknya keadaan pasien.

Beberapa penelitian mengenai klasifikasi kanker kulit berbasis AI sudah dilakukan. Pada sebuah penelitian dilakukan deteksi kanker kulit menggunakan *convolutional neural network (CNN)* dengan pengecekan pada citra menggunakan metode *asymmetry*, *border*, *color*, *diameter*, and *evolution (ABCDE)* [3]. Pada metode ini, citra terbagi atas kelas jinak dan ganas dengan hasil keluaran berupa kelas 1 atau 0. Nilai 1 berarti citra mengandung sel kanker ganas dan 0 berarti citra tidak mengandung sel kanker. Akurasi terbaik yang dihasilkan adalah 89,5%. Referensi [4] melakukan deteksi kanker kulit pada sel *dermal* berbasis *deep learning*, menggunakan Deep Learning Studio sebagai platform arsitektur. Penelitian lainnya telah melakukan deteksi dan klasifikasi kanker kulit menggunakan *transfer learning* yang mengombinasikan arsitektur VGG19, Inception V3, SqueezeNet, dan ResNet50 untuk meningkatkan akurasi [5]. Pada [6] telah dilakukan deteksi dan klasifikasi kanker kulit menggunakan *support vector machine (SVM)* melalui metode *kernel SVM* dan basis fungsi radial untuk mendeteksi data dan membaginya ke dalam kelas kanker jinak atau kanker ganas. Hasil akurasi terbaik yang

^{1,2,3} Program Studi Teknik Telekomunikasi Fakultas Teknik Elektro Universitas Telkom, Jl. Telekomunikasi No. 1, Terusan Buahbatu, Dayeuhkolot, Kabupaten Bandung, Jawa Barat 40257 (e-mail: ¹sofiasaidahsfi@telkomuniversity.ac.id, ²yowansuparta@student.telkomuniversity.ac.id ³efrisuhartono@telkomuniversity.ac.id)

[Diterima: 18 Februari 2022, Revisi: 21 Maret 2022]

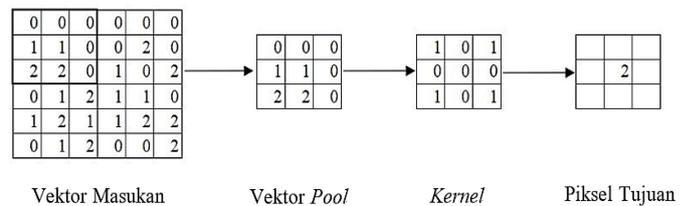
dihasilkan adalah 92,10%. Penelitian berikutnya menggunakan model *two dropout layers*-CNN, sebuah metode *deep learning* dan *machine learning* untuk membedakan objek, termasuk jenis kanker, termasuk kanker ganas atau jinak [7]. Akurasi terbaik yang diperoleh adalah 88,40%. Referensi [8] memanfaatkan *computer-aided diagnosis* (CAD) untuk mendeteksi kanker kulit berdasarkan aturan ABCD, dengan hasil akurasi terbaik yang diperoleh adalah 92,00%. Selanjutnya, pada [9] digunakan *differential evolution based artificial neural network* (DE-ANN) dan segmentasi otomatis menggunakan *fuzzy c-means clustering*, dengan akurasi terbaik sebesar 97,40%. Pada [10], *deep convolutional neural network* (DCNN) dimanfaatkan untuk ekstraksi data dan klasifikasi kanker kulit, dengan akurasi terbaik yang diperoleh adalah 95,41%. Pada penelitian berikutnya dilakukan diagnosis kanker kulit menggunakan CNN arsitektur GoogLeNet yang dimodifikasi dengan menambahkan *transposed convolutional layers* (*deconvolution*) setelah konvolusi terakhir, yang memperoleh tingkat akurasi sebesar 93,09% [11].

CNN adalah metode klasifikasi yang dapat digunakan pada klasifikasi citra digital, khususnya pada citra kanker kulit. Metode ini diharapkan dapat membantu dokter mendiagnosis penyakit kanker kulit pada lapisan epidermis lebih akurat, sehingga tepat dalam menentukan langkah pengobatan selanjutnya [12], [13]. Berdasarkan penelitian serupa [11], pada penelitian ini dimanfaatkan CNN arsitektur GoogLeNet dengan masukan citra yang lebih sedikit dibandingkan dengan penelitian sebelumnya, serta memberikan penambahan metode dengan pemanfaatan *dull razor filtering* yang berperan untuk mengurangi derau pada masukan citra yang diakibatkan oleh rambut-rambut halus serta penyeragaman ukuran citra sebagai masukan, sehingga metode ini dapat meningkatkan akurasi yang diperoleh jika dibandingkan dengan penelitian sebelumnya.

II. METODE YANG DIUSULKAN

A. Convolutional Neural Network

CNN merupakan salah satu metode *deep neural network* yang memiliki akurasi yang baik dalam *image recognition*. CNN adalah metode pengolahan citra, pengembangan dari *multilayer perceptron* (MLP), yang pada neuronnya data dipropagasikan dalam dua dimensi [14]. CNN adalah operasi *feed forward neural network* yang diimplementasikan berdasarkan cara kerja *visual cortex* manusia, menggunakan beberapa elemen yang bekerja secara paralel dengan mengolah data berpola *grid*. CNN terdiri atas beberapa lapisan (*layer*), yaitu lapisan konvolusi, lapisan *pooling*, dan *fully connected layer*, yang bekerja secara hierarki, sehingga keluaran pada lapisan sebelumnya akan menjadi masukan pada lapisan selanjutnya [15]. CNN merupakan metode *deep learning* yang terdiri atas banyak operasi matematika. Salah satu keunggulan metode CNN adalah tidak membutuhkan metode ekstraksi ciri tertentu, sehingga tahapan proses klasifikasi citra dapat berjalan lebih cepat. Namun, pada CNN dibutuhkan jumlah data yang jauh lebih banyak untuk proses pelatihan, sehingga beban komputasi menjadi lebih besar dan dibutuhkan unit pemrosesan grafis yang mahal dari segi biaya untuk pelatihan sistem.



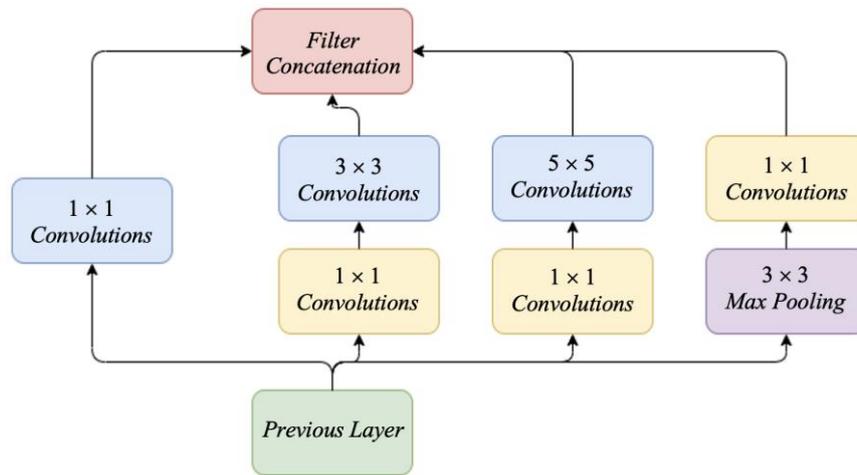
Gbr. 1 Proses konvolusi.

B. Arsitektur GoogLeNet

Arsitektur GoogLeNet adalah sebuah modifikasi arsitektur CNN yang berhasil menjadi model terbaik pada ILLSVRC14. Arsitektur ini bekerja dengan mendeteksi citra dengan lapisan yang dimiliki sejumlah lima hingga 22 lapisan, tetapi tetap memiliki akurasi yang tinggi. Konsep kerja arsitektur ini didasarkan pada *activation values* pada *deep network* yang tidak sepenuhnya penting karena terdapat *value of zero* akibat korelasi sebelumnya, sehingga dibutuhkan *activation values* yang tidak terkoneksi sepenuhnya [16]. Untuk memenuhi kondisi tersebut, pada GoogLeNet terdapat lapisan *inception module* yang terinspirasi dari model *visual cortex* manusia yang berperan untuk mengoptimalkan *sparse structure* sehingga menunjang komputasi. Pada arsitektur GoogLeNet, pada lapisan *inception module*, konvolusi dengan matriks 1×1 dilakukan sebelum konvolusi dengan matriks 3×3 dan 5×5 , guna mengurangi dimensi modul yang berperan meningkatkan kedalaman analisis serta perluasan *network* tanpa menurunkan kinerja sistem. Secara umum, pada arsitektur GoogLeNet, lapisan konvolusi dan *pooling* berperan dalam melakukan ekstraksi data, sedangkan *inception module* berperan dalam mengurangi beban komputasi dan meningkatkan kedalaman data, dan pada bagian akhir arsitektur GoogLeNet, *fully connected layer* berperan untuk menampung hasil proses lapisan *pooling*. Keluaran sistem akan diganti dengan *simple global average pooling* untuk mengurangi ukuran total parameter tanpa mengurangi akurasi [16].

1) *Lapisan Konvolusi*: Lapisan konvolusi merupakan lapisan yang melakukan fungsi matematika dengan mengaplikasikan *kernel* secara iteratif [14]. Lapisan ini menggunakan *array of number*, yang bernama *kernel*, yang diaplikasikan kepada masukan yang bernama *tensor*, yang juga merupakan *array of number*, untuk mengekstraksi citra masukan yang menghasilkan nilai keluaran yang kemudian disebut sebagai transformasi linear yang mengandung informasi spasial. Prosedur ini mengalami proses iterasi, sehingga terdapat beberapa bidang repetitif [15], [17]. Proses konvolusi diperlihatkan pada Gbr. 1.

2) *Stride*: *Stride* merupakan bagian yang mengontrol filter yang ditetapkan untuk melakukan fungsi konvolusi pada masukan citra [15]. Apabila *stride* bernilai 1, *kernel* akan melakukan pergeseran sebanyak 1 piksel horizontal dan vertikal. Makin kecil nilai *stride* yang digunakan, makin detail informasi yang diperoleh dari proses konvolusi. Meskipun demikian, hal ini akan menyebabkan waktu komputasi menjadi makin besar dan bukan berarti kinerja yang dihasilkan oleh sistem akan makin baik.



Gbr. 2 Representasi inception module.

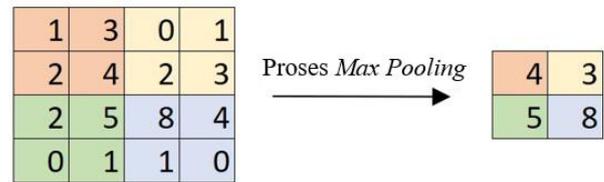
3) *Padding*: *Padding* adalah penambahan ukuran piksel dengan nilai tertentu untuk mengisi celah hasil konvolusi dari ujung awal hingga akhir [15]. Nilai yang biasanya digunakan adalah nol, sehingga disebut dengan *zero padding*, yang berfungsi untuk merekayasa hasil keluaran konvolusi agar tidak mengalami perbedaan dimensi yang signifikan dengan dimensi masukan. Hal ini akan memungkinkan hasil ekstraksi memiliki informasi yang makin mendalam.

4) *Fungsi Aktivasi*: Fungsi aktivasi adalah tahapan yang dilakukan setelah proses konvolusi selesai. Operasi ini memiliki berbagai jenis persamaan yang dapat dipakai, salah satunya adalah *rectification linear unit* (ReLU), yang menjalankan fungsi *non-linear* dan meningkatkan representasi model [15]. Hasil dari fungsi aktivasi ReLU akan berupa keluaran dengan nilai 0, jika masukan bernilai negatif. Nilai keluaran akan sama dengan nilai masukan apabila nilai masukan bernilai positif. Fungsi ReLU dapat dituliskan seperti pada (1).

$$f(x) = \begin{cases} 0, & x \leq 0 \\ x, & x > 0 \end{cases} \quad (1)$$

5) *Inception Module*: *Inception module* adalah lapisan yang memungkinkan seluruh filter (1 x 1, 3 x 3, dan 5 x 5) beroperasi pada bagian citra yang sama kemudian merangkai hasil dari konvolusi ke dalam satu keluaran dengan keluaran hasil dari lapisan *pooling*. *Inception module* memungkinkan fungsi konvolusi dan proses *pooling* bekerja secara paralel yang hasilnya akan menjadi satu keluaran. Pada proses *inception*, terdapat penggunaan filter 1 x 1 sebelum melewati lapisan konvolusi lainnya dan *max pooling* untuk meringankan beban komputasi, sehingga tidak membebani kerja perangkat [18]. Cara kerja *inception module* diperlihatkan pada Gbr. 2.

6) *Lapisan Pooling*: Lapisan ini merupakan metode *down-sampling* atau *sub-sampling* pada dimensi spasial untuk mengurangi jumlah fitur yang diekstraksi pada suatu citra [19], [20]. Lapisan *pooling* menggunakan *kernel* pada proses reduksi piksel suatu citra. Jika citra masukan memiliki ukuran yang lebih kecil dari ukuran *kernel* yang digunakan, citra masukan akan diberikan *zero padding* terlebih dahulu [19]. Kemudian,



Gbr. 3 Operasi max pooling.

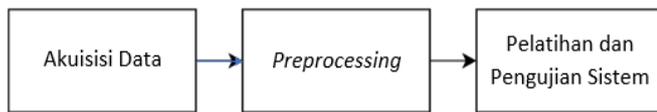
TABEL I
CONFUSION MATRIX

		Kelas Prediksi		
		Benar	Salah	Total
Kelas Sebenarnya	Benar	TP	FN	P
	Salah	FP	TN	N
	Total	P'	N'	P + N

kernel akan digeser sepanjang citra menggunakan proses konvolusi. Terdapat dua jenis operasi yang digunakan pada lapisan *pooling*, yaitu: *max pooling* dan *average pooling*. *Max pooling* mengambil nilai tertinggi dari setiap pergeseran *kernel*, sedangkan *average pooling* mengambil nilai rata-rata dari setiap tahap pergeseran *kernel*. *Max pooling* merupakan salah satu operasi yang paling banyak digunakan. Ilustrasi operasi *max pooling* ditunjukkan pada Gbr. 3.

7) *Simple Global Average Pooling*: *Simple global average pooling* merupakan salah satu jenis lapisan *pooling* yang menggunakan fungsi rata-rata. Lapisan *simple global average pooling* mengambil nilai rata-rata dari seluruh hasil *feature map*, yang berdampak pada pengurangan ukuran parameter keluaran [16]. *Simple global average pooling* memiliki kemiripan dengan struktur konvolusi dengan melakukan operasi korenspondensi antara *feature maps* dan kategori, sehingga memudahkan proses klasifikasi. Hal ini juga meringankan beban komputasi. Selain memudahkan klasifikasi, pada *simple global average pooling* tidak terdapat parameter untuk melakukan optimasi, sehingga *overfitting* dapat dihindari [21].

8) *Dropout*: *Dropout* digunakan dengan menghilangkan beberapa neuron secara acak pada proses pelatihan. Masing-



Gbr. 4 Sistem secara umum.

masing neuron memiliki bobot probabilitas yang sama [22]. Proses ini bertujuan untuk mengurangi beban komputasi sehingga meningkatkan kinerja *network*.

9) *Confusion Matrix*: *Confusion matrix* adalah matriks yang digunakan untuk mengukur kinerja model klasifikasi dengan cara membandingkan informasi kelas yang seharusnya dengan hasil klasifikasi yang dihasilkan [23]. Terdapat empat elemen dalam *confusion matrix*. Yang pertama adalah *true positive* (TP), yaitu kondisi saat kelas yang sebenarnya benar dan keluaran juga menunjukkan hasil benar. Keadaan selanjutnya adalah *true negative* (TN), yaitu kondisi kelas yang sebenarnya salah dan hasil prediksi juga salah. Selanjutnya, pada kondisi *false positive* (FP), keadaan kelas sebenarnya salah, tetapi hasil prediksi mengatakan benar. Terakhir, kondisi *false negative* (FN) merupakan kondisi saat kelas sebenarnya benar, tetapi hasil prediksi mengatakan salah [23]. Representasi *confusion matrix* ditunjukkan oleh Tabel I.

10) *Perancangan Sistem*: Pada penelitian ini dilakukan beberapa tahapan dalam melakukan deteksi jenis kanker kulit, termasuk kanker kulit ganas atau jinak. Tahapan yang dilakukan ditunjukkan pada Gbr. 4.

Dari Gbr. 4 dapat dilihat bahwa penelitian dimulai dengan tahap pertama, yaitu akuisisi data. Data yang digunakan adalah citra kanker kulit jinak dan ganas yang merupakan data sekunder yang diperoleh melalui web *www.kaggle.com*. Total data yang digunakan adalah enam ratus data citra kanker kulit, yang terdiri atas 132 citra data uji dan 528 citra data latih.

Tahapan selanjutnya adalah *preprocessing*, yaitu *resizing*, yang dilakukan untuk menyeragamkan ukuran citra. Kemudian dilakukan tahapan untuk menghilangkan piksel rambut halus pada citra kulit dengan menggunakan *dullrazor filtering*.

Tahap terakhir adalah proses utama dengan metode CNN. Pada proses ini dilakukan ekstraksi fitur dan klasifikasi untuk mengetahui jenis citra kanker kulit, ganas atau jinak. Pada proses utama dilakukan tahap pelatihan dan pengujian.

Tahap pelatihan dilakukan untuk mencari nilai piksel yang digunakan sebagai acuan basis data. Metode yang digunakan untuk pelatihan adalah CNN arsitektur GoogLeNet karena metode ini memiliki kemampuan untuk melakukan klasifikasi dari sebuah citra yang diproses ke seluruh lapisan dengan tingkat kedalaman yang berbeda-beda. Pada proses pelatihan, total iterasi yang dilakukan sebanyak 125 iterasi (nilai *epoch* 125) dengan *batch size* 32.

Tahap selanjutnya adalah pengujian terhadap sistem yang telah dirancang. Pengujian diawali dengan melakukan pengujian terhadap ukuran citra. Selanjutnya dilakukan pengujian terhadap jenis *optimizer*. Tahap ketiga adalah pengujian nilai *learning rate* terbaik dan yang terakhir adalah pengujian nilai *epoch* (iterasi). Selanjutnya, dari beberapa tahapan pengujian, diperoleh nilai parameter kinerja sistem yang terbaik.

TABEL II
MODEL ARSITEKTUR GOOGLNET

Lapisan	Deskripsi Lapisan	Bentuk Keluaran
1	<i>Input Layer</i>	<i>None</i> , 64, 64, 3
2	<i>Conv2D</i>	<i>None</i> , 64, 64, 64
3	<i>Max Pooling</i>	<i>None</i> , 32, 32, 64
4	<i>Conv2D</i>	<i>None</i> , 32, 32, 64
5	<i>Conv2D</i>	<i>None</i> , 32, 32, 192
6	<i>Max Pooling</i>	<i>None</i> , 16, 16, 192
7	<i>Inception (3a)</i>	<i>None</i> , 16, 16, 256
8	<i>Inception (3b)</i>	<i>None</i> , 16, 16, 480
9	<i>Max Pool</i>	<i>None</i> , 8, 8, 480
10	<i>Inception (4a)</i>	<i>None</i> , 8, 8, 512
11	<i>Inception (4b)</i>	<i>None</i> , 8, 8, 512
12	<i>Inception (4c)</i>	<i>None</i> , 8, 8, 512
13	<i>Inception (4d)</i>	<i>None</i> , 8, 8, 528
14	<i>Inception (4e)</i>	<i>None</i> , 8, 8, 832
15	<i>Max Pool</i>	<i>None</i> , 4, 4, 832
16	<i>Inception (5a)</i>	<i>None</i> , 4, 4, 832
17	<i>Inception (5b)</i>	<i>None</i> , 4, 4, 1024
18	<i>Average Pool</i>	<i>None</i> , 1, 1, 1024
19	<i>Dropout</i>	<i>None</i> , 1, 1, 1024
20	<i>Flatten</i>	<i>None</i> , 1024
21	<i>Dense</i>	<i>None</i> , 2
22	<i>Sigmoid</i>	<i>None</i> , 2

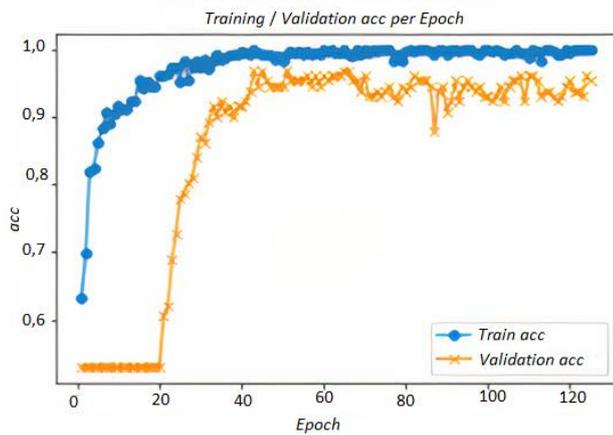
11) *Konfigurasi Model CNN*: Pada penelitian ini, dirancang sebuah sistem untuk mendeteksi jenis sel kanker kulit termasuk jenis yang ganas atau jinak. Sistem dirancang dengan metode CNN arsitektur GoogLeNet. Konsep dari arsitektur GoogLeNet dapat dilihat dari *inception module*-nya, yaitu proses konvolusi pada GoogLeNet berbeda dengan arsitektur lainnya karena menggunakan konvolusi 1×1 , 3×3 , 5×5 , dan *max pooling* yang dilakukan secara paralel dalam waktu yang bersamaan. Tabel II menunjukkan model arsitektur GoogLeNet yang digunakan.

Pada Tabel II, data masukan citra berupa citra sel kanker kulit masuk ke dalam model CNN arsitektur GoogLeNet. Pada penelitian ini, proses konvolusi dan *max pooling* yang dilakukan secara bersamaan digabungkan menjadi satu dalam *concatenation*. Selanjutnya, tahap klasifikasi dimulai dengan *flatten*, yaitu mengubah susunan data menjadi satu dimensi. *Dropout* berfungsi sebagai batas untuk neuron yang masuk, sedangkan *sigmoid* digunakan untuk mengklasifikasikan citra sel kanker kulit menjadi kelas ganas atau jinak.

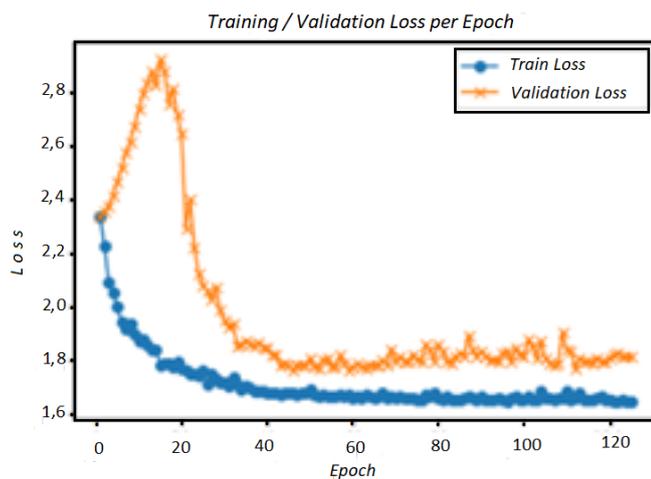
Untuk melihat keberhasilan model yang dirancang, dilakukan pengukuran terhadap beberapa parameter, seperti akurasi, *loss*, presisi, *recall*, dan *F1-score*. Parameter-parameter tersebut selanjutnya ditentukan dengan bantuan *confusion matrix*.

III. HASIL DAN PEMBAHASAN

Tahapan pengujian dilakukan setelah proses pelatihan selesai. Data citra uji yang digunakan sebanyak 132 data, yang terdiri atas 61 citra kanker kulit jinak dan 71 citra kanker kulit



Gbr. 5 Grafik akurasi pada proses latih dan uji.

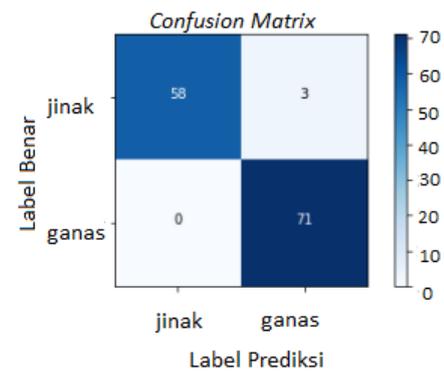


Gbr. 6 Grafik loss pada proses latih dan uji.

ganah. Setelah melalui beberapa tahap pengujian, dihasilkan beberapa parameter terbaik. Hasil penelitian menunjukkan bahwa parameter paling optimal yang menghasilkan kinerja terbaik di antaranya adalah ukuran citra 64×64 , *SGD optimizer*, *learning rate* 0,001, dan model *loss cross categorical entropy*. Hasil pengujian akurasi dan *loss* dengan menggunakan model CNN yang diusulkan pada penelitian ini ditunjukkan pada Gbr. 5 dan Gbr. 6.

Gbr. 5 menunjukkan akurasi untuk setiap iterasi pada proses latih dan uji. Dari Gbr. 5 terlihat bahwa hasil penelitian tidak menunjukkan terjadinya *overfitting*. Hal ini berarti perbedaan nilai akurasi pada proses latih dan validasi (uji) tidak terlalu signifikan. Demikian pula pada Gbr. 6, nilai *loss* yang dihasilkan pada proses latih dan validasi (uji) tidak menghasilkan perbedaan yang signifikan. Gbr. 6 ini menunjukkan adanya penurunan nilai *loss* pada proses latih maupun validasi. Kinerja terbaik yang dihasilkan pada penelitian ini yaitu 97,73% untuk akurasi dan 1,7063 untuk *loss*.

Sementara itu, Gbr. 7 menunjukkan *confusion matrix* hasil pengujian sistem. Dari gambar tersebut, dapat dilihat bahwa dari sebanyak 132 data uji yang digunakan, sebagian besar data uji dapat diklasifikasikan dengan benar sesuai dengan kelas



Gbr. 7 Confusion matrix sistem klasifikasi kanker kulit.

TABEL III
PARAMETER PERFORMA SISTEM DARI MODEL CNN YANG DIUSULKAN

Kelas	Pesisi	Recall	F-1 Score	Jumlah Data
Jinak	1,00	0,95	0,97	61
Ganah	0,96	1,00	0,98	71
Rata-rata	0,98	0,98	0,98	132

jenis kanker kulit yang ada. Selain itu, pada Tabel II dapat dilihat parameter kinerja lainnya, yaitu *F1-score*, *recall*, dan presisi dengan nilai rata-rata yang dihasilkan untuk setiap parameter adalah 0,98. Hal ini menunjukkan bahwa model CNN arsitektur GoogLeNet yang diusulkan pada penelitian ini memiliki akurasi yang terbilang tinggi untuk dapat mengklasifikasikan dua kelas kanker kulit yang terdiri atas kanker kulit jinak dan kanker kulit ganah. Parameter kinerja sistem yang dihasilkan disajikan pada Tabel III. Selain akurasi dan *loss*, diukur pula nilai presisi, *recall*, dan *f-1 score* untuk setiap jenis kelasnya. Nilai rata-rata yang dihasilkan dari ketiga parameter tersebut adalah 0,98.

Jika dibandingkan dengan penelitian sebelumnya, ada beberapa hal yang menjadi fokus [11]. Pertama, pada *dataset* yang digunakan, penelitian ini hanya menggunakan *dataset* asli, sementara pada [11] digunakan data hasil augmentasi. Pada tahap *preprocessing*, penelitian pada [11] hanya melakukan proses *resizing*, sementara pada penelitian ini dilakukan proses *resizing* dan juga penghilangan piksel rambut halus dengan *dullrazor filtering*. Dari segi kinerja sistem, akurasi terbaik pada [11] adalah 93,09%, sementara pada penelitian ini akurasi terbaik yang dihasilkan adalah 97,73%. Hal ini terjadi karena objek yang dideteksi pada penelitian ini terlihat lebih jelas setelah dilakukan penghilangan piksel rambut halus dengan *dullrazor filtering* secara manual.

IV. KESIMPULAN

Pada penelitian ini, dirancang sebuah sistem untuk mengklasifikasikan jenis kanker kulit jinak dan kanker kulit ganah. Data citra kanker kulit yang digunakan adalah data sekunder yang diperoleh dari web www.kaggle.com. Sebanyak 660 data yang digunakan dibagi menjadi 132 data uji dan 528 data latih. Dengan menggunakan metode CNN arsitektur GoogLeNet, dapat disimpulkan bahwa sistem yang dirancang mampu mengklasifikasikan dua jenis kanker kulit yang ada. Hasil yang diperoleh pada penelitian ini yaitu akurasi 97,73%

dan *loss* 1,7063. Untuk parameter lainnya, seperti *f-1 score*, *recall*, dan presisi, diperoleh nilai rata-rata sebesar 0,98. Untuk penelitian selanjutnya, disarankan agar digunakan metode *deep learning* lainnya, sehingga diperoleh akurasi yang lebih baik dalam membedakan kelas kanker kulit jinak dan ganas. Selain itu, implementasi dalam bentuk aplikasi dapat juga dilakukan agar pendeteksian jenis kanker kulit dapat dilakukan secara *real-time*.

KONFLIK KEPENTINGAN

Tim Penulis menyatakan bahwa artikel yang berjudul “Modifikasi *Convolutional Neural Network* Arsitektur GoogLeNet dengan *Dull Razor Filtering* untuk Klasifikasi Kanker Kulit” ditulis dengan bebas dari konflik kepentingan.

KONTRIBUSI PENULIS

Konseptualisasi, Sofia Saidah dan Efri Suhartono; metodologi, I Putu Yowan Nugraha Suparta; penulisan—penyusunan draf asli, Sofia Saidah; peninjauan dan penyuntingan, Efri Suhartono dan I Putu Yowan Nugraha Suparta.

REFERENSI

- [1] A. Rosana, P. Wijaya, dan F. Bimantoro, “Sistem Pakar Diagnosis Penyakit Kulit pada Manusia dengan Metode Dempster Shafer,” *J-COSINE*, Vol. 4, No. 2, hal. 129–138, 2020.
- [2] S. Wilvestra, S. Lestari, dan E. Asri, “Studi Retrospektif Kanker Kulit di Poliklinik Ilmu Kesehatan Kulit dan Kelamin RS Dr. M. Djamil Padang Periode Tahun 2015-2017,” *J. Kesehat. Andalas*, Vol. 7, Supp. 3, hal. 47-49, 2018.
- [3] M. Hasan, S. Das Barman, S. Islam, dan A.W. Reza, “Skin Cancer Detection Using Convolutional Neural Network,” *ICCAI '19: Proc. 2019 5th Int. Conf. Comput., Artif. Intell.*, 2019, hal. 254–258.
- [4] M.A. Kadampur dan S. Al Riyae, “Skin Cancer Detection: Applying a Deep Learning based Model Driven Architecture in the Cloud for Classifying Dermal Cell Images,” *Inform. Med. Unlocked*, Vol. 18, hal. 1-6, 2020.
- [5] A. Khamparia, dkk., “An Internet of Health Things-Driven Deep Learning Framework for Detection and Classification of Skin Cancer Using Transfer Learning,” *Trans. Emerg. Telecommun. Technol.*, Vol. 32, No. 7, hal. 1–11, 2021.
- [6] H. Alquran, dkk., “The Melanoma Skin Cancer Detection and Classification Using Support Vector Machine,” *2017 IEEE Jordan Conf. Appl. Electr. Eng. Comput. Technol. (AEECT 2017)*, 2017, hal. 1–5.
- [7] J. Daghrir, L. Tlig, M. Bouchouicha, dan M. Sayadi, “Melanoma Skin Cancer Detection Using Deep Learning and Classical Machine Learning Techniques: A Hybrid Approach,” *2020 Int. Conf. Adv. Technol. Signal Image Process. (ATSIP 2020)*, 2020, hal. 1–5.
- [8] N.S. Zghal dan N. Derbel, “Melanoma Skin Cancer Detection Based on Image Processing,” *Curr. Med. Imaging Rev.*, Vol. 16, No. 1, hal. 50–58, 2018.
- [9] M. Kumar, dkk., “A DE-ANN Inspired Skin Cancer Detection Approach Using Fuzzy C-Means Clustering,” *Mob. Networks Appl.*, Vol. 25, No. 4, hal. 1319–1329, 2020.
- [10] T. Saba, M.A. Khan, A. Rehman, dan S.L. Marie-Sainte, “Region Extraction and Classification of Skin Cancer: A Heterogeneous Framework of Deep CNN Features Fusion and Reduction,” *J. Med. Syst.*, Vol. 43, No. 9, hal. 1-19, 2019.
- [11] E. Yilmaz dan M. Trocan, “A Modified Version of GoogLeNet for Melanoma Diagnosis,” *J. Inf. Telecommun.*, Vol. 5, No. 3, hal. 395–405, 2021.
- [12] J. Höhn, dkk., “Combining CNN-based Histologic Whole Slide Image Analysis and Patient Data to Improve Skin Cancer Classification,” *Eur. J. Cancer*, Vol. 149, hal. 94–101, 2021.
- [13] M. Wardhana, dkk., “Karakteristik Kanker Kulit di Rumah Sakit Umum Pusat Sanglah Denpasar tahun 2015-2018,” *Intisari Sains Medis*, Vol. 10, No. 1, hal. 260–263, 2019.
- [14] I.W. Suartika E.P, A.Y. Wijaya, dan R. Soelaiman, “Klasifikasi Citra Menggunakan Convolutional Neural Network (CNN) pada Caltech 101,” *J. Tek. ITS*, Vol. 5, No. 1, hal. A65-A69, 2016.
- [15] E.N. Arrofiqoh dan H. Harintaka, “Implementasi Metode Convolutional Neural Network untuk Klasifikasi Tanaman pada Citra Resolusi Tinggi,” *Geomatika*, Vol. 24, No. 2, hal. 61-68, 2018.
- [16] N. Bi, J. Chen, dan J. Tan, “The Handwritten Chinese Character Recognition Uses Convolutional Neural Networks with the GoogLeNet,” *Int. J. Pattern Recognit. Artif. Intell.*, Vol. 33, No. 11, hal. 1-12, 2019.
- [17] R. Yamashita, M. Nishio, R.K.G. Do, dan K. Togashi, “Convolutional Neural Networks: An Overview and Application in Radiology,” *Insights Imaging*, Vol. 9, No. 4, hal. 611–629, 2018.
- [18] C. Szegedy, dkk., “Going Deeper with Convolutions,” *J. Chem. Technol. Biotechnol.*, Vol. 91, No. 8, hal. 2322–2330, 2015.
- [19] C.A. Dias, dkk., “Using the Choquet Integral in the Pooling Layer in Deep Learning Networks,” dalam *Fuzzy Information Processing. NAFIPS 2018. Communications in Computer and Information Science*, Vol. 831, G.A. Barreto dan R. Coelho, Eds., Cham, Swiss: Springer, 2018, hal. 119–131.
- [20] L. Wu dan G. Perin, “On the Importance of Pooling Layer Tuning for Profiling Side-Channel Analysis,” dalam *Applied Cryptography and Network Security Workshops. ACNS 2021. Lecture Notes in Computer Science*, Vol. 12809, Cham, Swiss: Springer, 2021, hal. 114–132.
- [21] M. Lin, Q. Chen, dan S. Yan, “Network in Network,” *2nd Int. Conf. Learn. Represent. (ICLR 2014) - Conf. Track Proc.*, 2014, hal. 1–10.
- [22] A. Poernomo dan D.K. Kang, “Biased Dropout and Crossmap Dropout: Learning Towards Effective Dropout Regularization in Convolutional Neural Network,” *Neural Netw.*, Vol. 104, hal. 60–67, 2018.
- [23] R. Herwanto, K. Gunadi, dan E. Setyati, “Pengenalan Golongan Jenis Kendaraan Bermotor pada Ruas Jalan Tol Menggunakan CNN,” *J. Infra Petra*, Vol. 8, No. 1, hal. 196–202, 2020.