

Deep Transfer Learning untuk Meningkatkan Akurasi Klasifikasi pada Citra Dermoskopi Kanker Kulit

Qorry Aina Fitroh¹, Shofwatul 'Uyun²

^{1,2} Program Studi Informatika Fakultas Sains dan Teknologi Universitas Islam Negeri Sunan Kalijaga, Yogyakarta 55281 INDONESIA (tel.: 0274-512474; fax: 0274-586117; email: ¹qorryafitroh@gmail.com, ²shofwatul.uyun@uin-suka.ac.id)

[Diterima: 27 Desember 2022, Revisi: 2 Maret 2023]

Corresponding Author: Qorry Aina Fitroh

INTISARI — Kanker kulit *benign* (jinak) dan *malignant* (ganas) merupakan jenis kanker kulit yang sering dijumpai. Tanda-tanda kanker kulit penting untuk diketahui dengan diagnosis dini agar dapat diberikan penanganan yang tepat, sehingga dapat mengurangi tingkat kematian penderitanya. Citra dermoskopi menjadi salah satu media diagnosis yang telah banyak dikembangkan oleh peneliti. Analisis citra dermoskopi memberikan hasil lebih optimal dalam diagnosis berbasis komputasi dibandingkan deteksi visual. Model yang berhasil diterapkan dalam diagnosis berbasis komputasi tersebut di antaranya *deep learning* dan *transfer learning*, tetapi masih diperlukan optimalisasi. Pada penelitian ini, dilakukan klasifikasi citra dermoskopi kanker kulit ke dalam dua kelas (*benign* dan *malignant*) dengan memanfaatkan *transfer learning*. Untuk meningkatkan akurasi penelitian yang telah dilakukan sebelumnya pada *dataset* publik dari Kaggle dengan jumlah 3.297 citra, penelitian ini menggunakan 2.000 citra. Penelitian ini membandingkan dua *pre-trained model*, yaitu VGG-16 dan *residual network* (ResNet)-50 yang digunakan sebagai *feature extractor*. Selanjutnya dilakukan *fine-tuning* dengan menambahkan *flatten layer*, dua *dense layer* dengan fungsi aktivasi ReLU, dan satu *dense layer* dengan fungsi aktivasi Softmax untuk melakukan klasifikasi ke dalam dua kelas. *Hyper parameter tuning* pada *optimizer*, *batch size*, *learning rate*, dan *epoch* dilakukan untuk mendapatkan kombinasi parameter dengan kinerja terbaik pada masing-masing model. Sebelum dilakukan *hyper parameter tuning*, model diuji dengan *resize* citra masukan menggunakan ukuran yang berbeda-beda. Hasil pengujian model menggunakan citra uji pada model VGG-16 memberikan kinerja terbaiknya pada ukuran citra 128×128 piksel dengan kombinasi parameter Adam sebagai *optimizer*, *batch size* 64, *learning rate* 0,001, dan *epoch* 10 dengan nilai akurasi 91% dan *loss* 0,2712. Model ResNet-50 memberikan akurasi yang lebih baik, yaitu 94%, dan *loss* 0,2198 dengan parameter *optimizer* RMSprop, *batch size* 64, *learning rate* 0,0001, dan *epoch* 100. Hasil pengujian ini menunjukkan bahwa metode yang diusulkan memberikan akurasi yang baik dan dapat membantu dermatologi dalam deteksi dini kanker kulit.

KATA KUNCI—*Transfer Learning*, *Deep Learning*, CNN, VGG-16, ResNet-50, Kanker Kulit, Klasifikasi.

I. PENDAHULUAN

Kanker dapat menjadi salah satu penyebab kematian manusia. Berdasarkan data WHO pada tahun 2020, hampir sepuluh juta kematian disebabkan oleh kanker [1]. Berbagai jenis kanker dapat hidup dalam tubuh manusia. Kanker kulit adalah salah satu kanker yang tumbuh paling cepat dan dapat menyebabkan kematian [2]. Kanker kulit muncul pada kulit terluar, yaitu epidermis, yang dapat dilihat oleh mata secara langsung [3]. *Malignant* (ganas) dan *benign* (jinak) merupakan jenis kanker kulit yang paling mematikan [4]. Kanker *malignant* dapat menyebar dan berkembang di tubuh penderitanya dengan cara menyusup ke jaringan dan organ lain serta berkembang dan menyebar tanpa terkendali. Sementara itu, kanker *benign* dapat berkembang, tetapi tidak akan menyebar. Maka, tanda-tanda umum dan gejala kanker *benign* berubah menjadi *malignant* perlu diketahui. Diagnosis dini pada awal gejala dapat membantu penderita untuk memiliki kesempatan bertahan hidup lebih besar [5]. Tahap awal diagnosis kanker kulit dilakukan melalui pemeriksaan secara visual, diikuti biopsi, dan pemeriksaan histopatologi [6]. Teknik diagnosis lain dikembangkan berdasarkan analisis komputasi citra dermoskopi untuk klasifikasi lesi kulit secara otomatis yang dapat membantu dokter dalam mendeteksi penyakit dan mengambil keputusan diagnostik serta memungkinkan akses yang cepat dan murah [7], [8].

Citra dermoskopi merupakan metode pencitraan kulit yang paling terkenal. Dermoskopi terbukti lebih akurat daripada pemeriksaan visual secara langsung oleh tenaga medis. Hal ini terjadi karena citra dermoskopi memungkinkan visualisasi berbagai fitur yang tidak dapat dilihat oleh mata secara

langsung, sehingga struktur bawah permukaan lesi kulit dapat dianalisis dan berbagai jenis lesi dapat dibedakan menggunakan visualisasi yang lebih baik [9], [10]. Penggunaan citra dermoskopi menyebabkan diagnosis kanker kulit menjadi lebih baik dibandingkan deteksi dengan pemeriksaan visual secara langsung, seperti klasifikasi citra kanker kulit yang dilakukan dengan menggunakan dua *dataset* citra dermoskopi yang berbeda, yaitu HAM10000 dengan 10.000 citra dan BCN20000 dengan 19.424 citra [3]. Penelitian tersebut mendapatkan akurasi 94,92%. *Dataset* yang sama (HAM10000) menghasilkan akurasi 91,43% pada penelitian lainnya [2]. Citra dermoskopi kanker kulit sejumlah 4.000 citra digunakan dalam klasifikasi menggunakan *convolutional neural network* (CNN) dengan memanfaatkan VGG-16 dan melakukan *hyper parameter tuning*, dengan akurasi yang diperoleh adalah sebesar 99,7% [11]. Selanjutnya, *dataset* publik dari Kaggle sejumlah 6.594 dilatih menggunakan model VGG-16 dan mendapatkan akurasi 93,18% [4]. Penelitian dengan membandingkan jumlah dua *dataset* yang berbeda, yaitu 10.000 citra dan 3.297 citra, untuk melakukan klasifikasi kanker kulit menunjukkan hasil bahwa penggunaan *dataset* dengan jumlah citra yang lebih banyak tidak memberikan perbedaan akurasi yang signifikan [6].

Perkembangan sains dan teknologi yang mendukung deteksi kanker kulit berdasarkan analisis citra menunjukkan progres yang terus membaik [12]. Analisis citra kanker kulit menggunakan algoritma *machine learning* klasik mampu memberikan hasil yang baik dalam klasifikasi kanker kulit tertentu. Akan tetapi, algoritma ini tidak efektif untuk kasus diagnosis yang lebih rumit dalam praktik klinis [13]. Proses

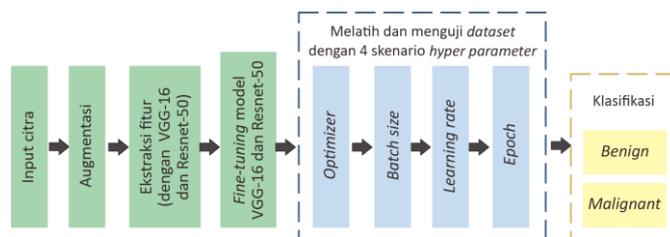
ekstraksi dan pemilihan fitur membutuhkan waktu yang lama. Selain itu, kesalahan dan kehilangan data pada tahap pemrosesan berpengaruh besar terhadap kualitas klasifikasi [7], [14]. Berbagai tantangan dari *machine learning* klasik dapat diatasi dengan metode *deep learning* yang menunjukkan kinerja signifikan dan dapat menganalisis data dari *dataset* yang besar dengan lebih cepat dan lebih akurat [8], [13], [15]. CNN merupakan salah satu metode *deep learning* yang memberikan hasil signifikan dengan akurasi yang baik pada pengenalan citra [16], [17]. CNN telah digunakan untuk mendeteksi citra dermoskopi melanoma dan mendapatkan nilai rata-rata sensitivitas dan spesifisitas sebesar 86,6% dan 71,3% [18]. Hal yang sama dilakukan pada [19], yang menggunakan CNN untuk mengklasifikasikan citra dermoskopi melanoma dan memperoleh nilai sensitivitas rata-rata 89,4% serta spesifisitas rata-rata 68,2%.

Penelitian untuk mendeteksi kanker payudara dengan CNN diterapkan melalui tiga skenario, yaitu pelatihan CNN dari nol (*full training*), menggunakan *pre-trained CNN* untuk ekstraksi fitur, dan melakukan *fine-tuning* pada *pre-trained CNN model* [20]. Akurasi terbaik dihasilkan dari metode kedua dan ketiga dengan akurasi model *fine-tuning* 0,008 lebih tinggi daripada model ekstraksi fitur. Penelitian ini menerapkan *transfer learning* pada CNN, yang merupakan solusi menjanjikan dalam deteksi kanker payudara. *Transfer learning* terbukti dapat meningkatkan akurasi dan mempercepat proses pelatihan [15]. *Transfer learning* telah digunakan untuk melakukan klasifikasi citra wajah manusia dengan *pre-trained model* Inception-v3 dan mendapatkan hasil akurasi rata-rata sebesar 93% [21]. Selain itu, klasifikasi citra menjadi dua kelas yang dilakukan menggunakan *deep CNN* dengan *pre-trained VGG-16 model* dan *fine-tuning* serta augmentasi citra memperoleh akurasi 95,40% [22]. Sementara itu, pada [23] dibandingkan *pre-trained CNN model*, yaitu VGG-16, VGG-19, dan *residual network* (ResNet)-50 dengan dua skenario (pelatihan dari nol dan *transfer learning*). Akurasi terbaik adalah 92,60% dengan skenario *transfer learning* menggunakan VGG-16 dan dilakukan *fine-tuning*. *Transfer learning* dengan berbagai *pre-trained model* dibandingkan dalam mengklasifikasikan sel darah putih [24] dan kanker kulit [25]. Keduanya menunjukkan hasil kinerja terbaik dalam penerapan ResNet-50 sebagai *pre-trained model*.

Penelitian ini melakukan optimasi dalam klasifikasi kanker kulit menjadi dua kelas (*benign* dan *malignant*) dengan menggunakan *transfer learning* dan diterapkan *fine-tuning* terhadap *optimizer*, *batch size*, *learning rate*, dan *epoch*. *Pre-trained model* yang digunakan yaitu VGG-16 dan ResNet-50. *Dataset* yang digunakan berasal dari *database* Kaggle yang berbentuk citra dermoskopi kanker kulit.

II. METODOLOGI

Penelitian ini menerapkan dua *pre-trained CNN model*, yaitu VGG-16 dan ResNet-50. Kedua model tersebut diimplementasikan pada satu *dataset* yang sama, yaitu sebanyak 2.000 citra kanker kulit. Teknik yang digunakan adalah *deep transfer learning* untuk mengklasifikasikan citra dermoskopi kanker kulit dalam dua kelas, yaitu *benign* dan *malignant*. Alur pemrosesan citra ditunjukkan pada Gambar 1, yang diawali dengan penginputan citra dan dilanjutkan dengan prapemrosesan citra melalui augmentasi data. Kemudian, dilakukan ekstraksi fitur pada kedua *pre-trained model* yang selanjutnya kedua model tersebut dimodifikasi dengan melakukan *fine-tuning* pada *fully connected layer*-nya. Untuk



Gambar 1. Alur pemrosesan citra.

TABEL I
 DESKRIPSI DATASET

	Pelatihan	Validasi	Pengujian	Jumlah
<i>Benign</i>	640	160	200	1.000
<i>Malignant</i>	640	160	200	1.000
Jumlah	1.280	320	400	2.000

menguji *hyper parameter* terbaik pada kedua model, dilakukan pelatihan pada data latih terlebih dahulu, kemudian uji *hyper parameter* terhadap data uji untuk mendapatkan akurasi terbaik. Uji *hyper parameter* diterapkan menggunakan empat skenario, dengan skenario pertama adalah *optimizer*. Setelah mendapatkan jenis *optimizer* terbaik pada masing-masing model, selanjutnya *optimizer* terbaik tersebut diterapkan dalam skenario kedua, yaitu *batch size*. Nilai *batch size* terbaik digunakan untuk skenario uji selanjutnya, yaitu *learning rate*, dilanjutkan skenario terakhir, yaitu uji nilai *epoch*.

A. DATASET

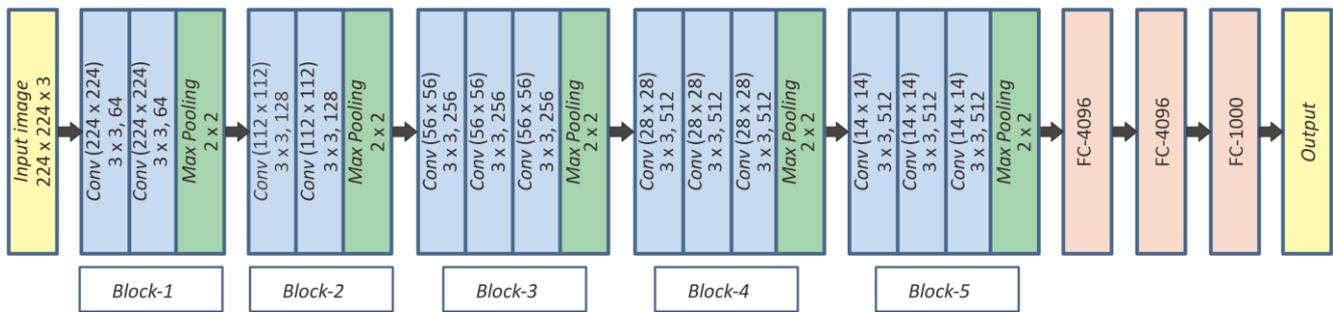
Penelitian ini menggunakan *dataset* publik yang berasal dari *database* Kaggle. *Dataset* tersebut terdiri atas citra *red green blue* (RGB) dengan total citra *benign* 1.800 dan citra *malignant* 1.497, dengan ukuran citra $224 \times 224 \times 3$ piksel. Jumlah citra dalam *dataset* adalah 3.297, tetapi penelitian ini hanya menggunakan 2.000 citra. Tabel I menunjukkan deskripsi *dataset* yang digunakan dalam penelitian ini. *Dataset* dibagi ke dalam data pelatihan dan data pengujian, dengan perbandingan 80:20. Selanjutnya, 20% dari data pelatihan digunakan untuk validasi dan sisanya digunakan untuk pelatihan model.

B. PRAPEMROSESAN DATA

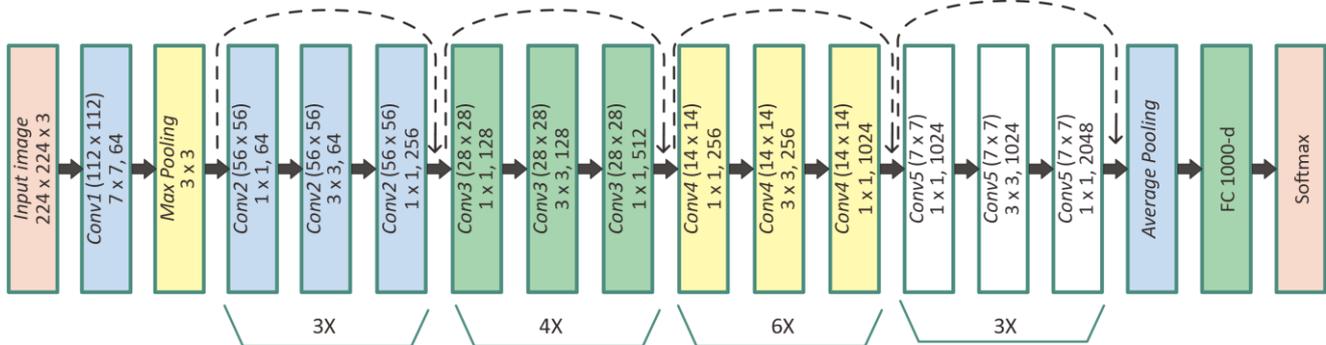
Tahap prapemrosesan meliputi perubahan ukuran (*resize*) citra dan augmentasi citra. Perubahan ukuran citra termasuk dalam skenario yang bertujuan untuk mengetahui kinerja terbaik. Ukuran citra diubah dari yang semula 224×224 piksel menjadi 128×128 piksel dan 64×64 piksel. Sementara itu, augmentasi citra bertujuan untuk memperbesar data pelatihan yang dilakukan secara artifisial. Augmentasi yang dilakukan meliputi rotasi, *zoom*, *horizontal flip*, dan translasi.

C. EKSTRAKSI FITUR

Metode *transfer learning* menggunakan *pre-trained CNN model* sebagai *feature extractor*. Selanjutnya, fitur yang telah diekstraksi digunakan untuk pelatihan pada lapisan (*layer*) baru [26]. *Pre-trained model* telah dilatih pada *dataset* raksasa, yaitu ImageNet, yang terdiri atas berbagai kategori citra. Maka, model tersebut telah mempelajari representasi citra dengan baik dan kemudian fitur itu dapat digunakan untuk *transfer knowledge* dan sebagai *feature extractor* pada *dataset* yang berbeda [22]. Cara menggunakan *pre-trained model* sebagai *feature extractor* adalah dengan membekukan lapisan yang berada di bawah dan melakukan kustomisasi pada lapisan atas. Penelitian ini menggunakan dua *pre-trained model* berbeda



Gambar 2. Arsitektur VGG-16.



Gambar 3. Arsitektur Resnet-50.

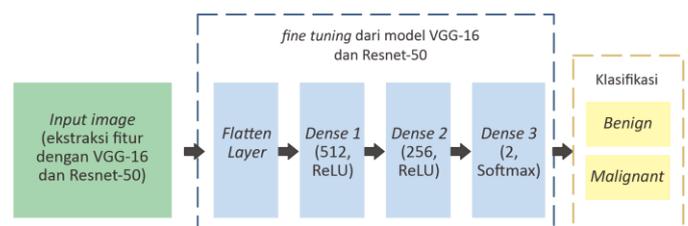
untuk mengklasifikasikan citra kanker kulit, yaitu VGG-16 dan ResNet-50.

1) VGG-16

Visual geometry group (VGG) merupakan arsitektur yang diusulkan oleh Simonyan dan Zisserman di University of Oxford dan menjadi pemenang dalam kompetisi ILSVRC 2014. VGG telah dilatih menggunakan *dataset* ImageNet ILSVRC sejumlah 1,3 juta data, yang terdiri atas 1.000 kelas [27]. Arsitektur ini diakui sebagai salah satu arsitektur dengan model terancang yang pernah dibuat, sehingga *pre-trained model* VGG-16 menjadi pilihan yang baik untuk melakukan *transfer learning* [4], [28]. Gambar 2 menunjukkan arsitektur VGG-16 yang terdiri atas lima blok. Blok pertama dan kedua tersusun atas dua lapisan konvolusi dan *max pooling* dengan filter masing-masing 64 dan 128. Blok ketiga hingga lima berisi tiga lapisan konvolusi, dengan filter masing-masing 256, 512, dan 512, dan satu lapisan *max pooling*. Pada penelitian ini, VGG-16 dimodifikasi dengan menambahkan satu *flatten layer*, dua *dense layer* dengan fungsi aktivasi *rectified linear unit* (ReLU), dan satu *dense layer* dengan fungsi aktivasi Softmax untuk meningkatkan akurasi model.

2) RESNET-50

Microsoft Research Asia (MRA) pada tahun 2015 mengusulkan model *deep neural network* dengan jaringan yang sangat dalam, yang dinamakan ResNet, dengan tujuan memastikan kinerja lapisan atas sebaik kinerja lapisan yang berada di bawahnya tanpa adanya *vanishing gradient* dan permasalahan optimasi [26]. ResNet memenangkan kompetisi ILSVRC 2015 dengan arsitektur pada ResNet-50 berupa jaringan *residual* yang terdiri atas 50 lapisan. Sesuai dengan namanya, jaringan ini menggunakan pembelajaran residual. Secara sederhana, residual merupakan proses pengurangan fitur yang telah dipelajari dari lapisan masukan (input) [24]. Arsitektur ResNet-50, seperti yang ditunjukkan dalam Gambar 3, terdiri atas rangkaian blok konvolusi dengan *average pooling*. Terdapat lima blok lapisan konvolusi. Setelah dilakukan penginputan citra, kemudian citra melewati lapisan



Gambar 4. Fine-tuning model VGG-16 dan ResNet-50.

konvolusi dengan 64 filter dan ukuran kernel 7×7 (lapisan *conv1*), dilanjutkan dengan *max pooling*. Selanjutnya, dalam *conv2*, lapisan dikelompokkan secara berpasangan sesuai dengan cara kerja ResNet. Proses ini dilakukan hingga lapisan konvolusi kelima dan dilanjutkan dengan *average pooling*. Softmax digunakan pada lapisan terakhir untuk klasifikasi.

D. SKENARIO FINE-TUNING

Fine-tuning pada model VGG-16 dan ResNet-50 ditunjukkan pada Gambar 4. Lapisan atas pada model, baik VGG-16 maupun ResNet-50, yang terdiri atas *fully connected layer* dan lapisan klasifikasi, dihapus dan diganti dengan dua *dense layer* dengan fungsi aktivasi ReLU yang masing-masing lapisannya terdiri atas 512 dan 256 neuron. *Dense layer* ketiga terdiri atas dua neuron dengan fungsi aktivasi Softmax. Setelah itu, citra diklasifikasikan ke dalam dua kelas kanker yang berbeda, yaitu *benign* dan *malignant*. Masukan pada *fine-tuning* berasal dari hasil ekstraksi fitur pada *pre-trained model*. Skenario ini berlaku bagi model VGG-16 dan ResNet-50. Selain itu, untuk mendapatkan kinerja terbaik, dilakukan *hyper parameter tuning* yang mencakup skenario *optimizer*, *batch size*, *learning rate*, dan *epoch*.

Fungsi aktivasi Softmax sering kali digunakan untuk klasifikasi *multi-class*. Fungsi ini muncul hampir dalam semua lapisan keluaran (*output layer*) dari arsitektur *deep neural network* [29]. Fungsi aktivasi Softmax merupakan generalisasi dari *sigmoid*. Perbedaan mendasar antara *sigmoid* dan Softmax adalah *sigmoid* hanya dapat digunakan untuk klasifikasi biner, sedangkan Softmax dapat digunakan untuk klasifikasi

multivariate. Fungsi aktivasi Softmax dan *sigmoid* digunakan untuk klasifikasi biner deteksi wajah pada karakter komik menggunakan metode *region-based CNN* (R-CNN). Hasil yang ditunjukkan tidak berbeda jauh. Klasifikasi dengan fungsi aktivasi *sigmoid* menunjukkan kinerja yang sedikit lebih baik daripada Softmax [30]. Sementara itu, fungsi aktivasi Softmax dan *sigmoid* yang diterapkan dalam model CNN untuk melakukan klasifikasi biner memperoleh skor 97,3% untuk Softmax dan 70,0% untuk fungsi aktivasi *sigmoid* [31].

Penelitian dengan membandingkan fungsi aktivasi Softmax dan *sigmoid* untuk klasifikasi biner serta Softmax untuk *multi-class* menggunakan lima tipe *neural network*, yaitu *separable convolutional neural network* (SCNN), *recurrent neural network* (RNN), *long short-term memory* (LSTM), *gated recurrent unit* (GRU), dan *fully connected network* (FCN) dengan menerapkan tiga skenario, menunjukkan hasil bahwa akurasi terbaik diperoleh Softmax dalam melakukan klasifikasi *multi-class* [32]. Sementara itu, untuk klasifikasi biner, SCNN memperoleh akurasi terbaik pada kedua fungsi aktivasi. Selain itu, pada kelima tipe *neural network* yang diterapkan, fungsi aktivasi Softmax memperoleh akurasi yang lebih unggul dibandingkan *sigmoid*. Dengan demikian, penggunaan fungsi aktivasi Softmax untuk menangani klasifikasi biner yang dianggap sebagai klasifikasi *multi-class* dengan dua kelas dapat meningkatkan akurasi pada kelima tipe *neural network* tersebut. Oleh karena itu, penelitian ini mengusulkan penerapan fungsi aktivasi Softmax pada lapisan keluaran untuk mengklasifikasikan citra kanker ke dalam dua kelas, yaitu *benign* dan *malignant*.

E. EVALUASI KINERJA

Kinerja dari eksperimen yang telah dilakukan diukur untuk mendapatkan tingkat keberhasilan dengan menggunakan *confusion matrix*. Hasil dari proses klasifikasi direpresentasikan melalui empat istilah dalam *confusion matrix*, yaitu *true positive* (TP), *true negative* (TN), *false positive* (FP), dan *false negative* (FN). Evaluasi kinerja dihitung berdasarkan nilai TP, TN, FP, dan FN, sehingga selanjutnya dapat diperoleh nilai akurasi, presisi, sensitivitas, maupun *f1-score* dari model yang diujikan. Akurasi dalam evaluasi kinerja merupakan ketepatan pengukuran tingkat kedekatan nilai prediksi terhadap nilai sebenarnya. Perhitungan nilai akurasi dilakukan menggunakan (1). Jumlah data yang terklasifikasikan benar positif dibandingkan dengan jumlah keseluruhan data kategori klasifikasi positif disebut dengan presisi, seperti yang dituliskan dalam (2). Sensitivitas, atau disebut juga *recall*, merupakan perbandingan jumlah data positif yang diklasifikasikan benar positif terhadap jumlah data positif yang sebenarnya, seperti pada (3). Nilai *f1-score* merupakan gabungan dari presisi dan sensitivitas, yang dapat diperoleh menggunakan (4).

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

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

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

$$F1 - Score = \frac{2 \times TP}{2 \times (TP+FP+FN)} \quad (4)$$

III. HASIL DAN PEMBAHASAN

Proses eksperimen menggunakan *fine-tuning* dilakukan dengan pembagian *dataset* seperti yang dideskripsikan pada Tabel I. Citra yang digunakan untuk pelatihan memiliki

TABEL II
PARAMETER MODEL VGG-16 YANG DIUSULKAN

Lapisan	Bentuk Keluaran	Parameter
VGG-16	4, 4, 512	14.714.688
Flatten	8.192	0
Dense_1	512	4.194.816
ReLU_1	512	0
Dense_2	256	131.328
ReLU_2	256	0
Dense_3	2	514
Jumlah parameter		19.041.346
Trainable parameters		4.326.658
Non-trainable parameters		14.714.688

TABEL III
PARAMETER MODEL RESNET-50 YANG DIUSULKAN

Lapisan	Bentuk Keluaran	Parameter
ResNet-50	7, 7, 2048	23.587.712
Flatten	100.352	0
Dense_1	512	51.380.736
ReLU_1	512	0
Dense_2	256	131.328
ReLU_2	256	0
Dense_3	2	514
Jumlah parameter		75.100.290
Trainable parameters		51.512.578
Non-trainable parameters		23.587.712

proporsi terbesar, yaitu sebanyak 640 citra pada setiap kelasnya, dengan tujuan untuk memastikan model mempelajari pola representasi dengan baik. Untuk menguji *hyper parameter* terbaik, dilakukan pelatihan terhadap data latih. Selanjutnya, *hyper parameter* yang telah diterapkan pada data latih digunakan dalam pengujian menggunakan data uji.

Sebelum melakukan *hyper parameter tuning*, dilakukan pengujian perubahan ukuran citra dengan tujuan untuk mendapatkan ukuran citra terbaik pada model VGG-16 dan ResNet-50 agar tercapai akurasi optimal. Pengujian dilakukan dengan menerapkan *hyper parameter* yang telah ditentukan sebelumnya, yaitu menggunakan *optimizer* Adam, *batch size* 64, *learning rate* 0,001, dan *epoch* 10. Ukuran citra yang akan diuji adalah 64×64 , 128×128 , dan 224×224 piksel. Hasil pengujian perubahan ukuran citra menunjukkan akurasi terbaik untuk model VGG-16 pada ukuran citra 128×128 piksel dengan nilai akurasi 0,9100, sedangkan ResNet-50 memperoleh ukuran terbaik pada ukuran citra 224×224 piksel dengan nilai akurasi 0,9050. Sementara itu, model VGG-16 dengan ukuran citra 224×224 piksel memberikan nilai akurasi lebih rendah, yaitu 0,8850, sedangkan ketika model ResNet-50 diuji dengan ukuran citra 128×128 piksel, diperoleh nilai akurasi 0,8975. Untuk ukuran citra 64×64 piksel, kedua model menghasilkan akurasi yang paling rendah di antara ukuran citra uji lainnya, yaitu 0,8875 untuk model VGG-16 dan 0,8750 untuk model ResNet-50. Berdasarkan hasil pengujian ukuran citra, dapat dikatakan bahwa akurasi VGG-16 lebih unggul dibandingkan ResNet-50 dengan berbagai faktor yang telah ditentukan sebelumnya.

Tabel II menunjukkan parameter dari model VGG-16 yang diusulkan, yaitu setelah dilakukan *fine-tuning*. Ukuran citra keluaran setelah model VGG-16 dengan ukuran citra masukan 128×128 piksel adalah 4×4 dan jumlah parameter yang dihasilkan adalah 14.714.468. Setelah itu, ditambahkan *flatten layer* yang memiliki ukuran keluaran 8.192. Terakhir, ditambahkan *Dense_1*, *Dense_2*, dan *Dense_3* yang menghasilkan 4.194.816, 131.328, dan 514 parameter. Berbeda

TABEL IV
HASIL PENGUJIAN SKENARIO PADA MODEL VGG-16 DAN RESNET-50

Model	Skenario 1: <i>Optimizer</i> (<i>batch size</i> 64, <i>learning rate</i> 0,001, <i>epoch</i> 10)			Skenario 2: <i>Batch Size</i> (<i>optimizer</i> : Adam-VGG-16; RMSProp-ResNet-50, <i>learning rate</i> 0,001, <i>epoch</i> 10)		
	<i>Optimizer</i>	<i>Test Acc</i>	<i>Test Loss</i>	<i>Batch Size</i>	<i>Test Acc</i>	<i>Test Loss</i>
VGG-16	Adam	0,9100	0,2712	32	0,8975	0,3029
	SGD	0,8875	0,2933	64	0,9100	0,2712
	RMSprop	0,8875	0,2448	128	0,8900	0,2931
ResNet-50	Adam	0,9050	0,2548	32	0,8825	0,2785
	SGD	0,8925	0,2629	64	0,9075	0,2420
	RMSprop	0,9075	0,2420	128	0,8725	0,3031
	Skenario 3: <i>Learning Rate</i> (<i>optimizer</i> : Adam-VGG-16; RMSProp-ResNet-50, <i>batch size</i> 64, <i>epoch</i> 10)			Skenario 4: <i>Epoch</i> (<i>optimizer</i> : Adam-VGG-16; RMSProp-ResNet-50, <i>batch size</i> 64, <i>learning rate</i> : 0,001-VGG-16; 0,0001-Resnet-50)		
	<i>Learning rate</i>	<i>Test Acc</i>	<i>Test Loss</i>	<i>Epochs</i>	<i>Test Acc</i>	<i>Test Loss</i>
VGG-16	0,01	0,8975	0,2811	10	0,9100	0,2712
	0,001	0,9100	0,2712	50	0,9025	0,2261
	0,0001	0,8700	0,2982	100	0,8975	0,2641
ResNet-50	0,01	0,8925	0,2494	10	0,9150	0,2342
	0,001	0,9075	0,2420	50	0,9075	0,2255
	0,0001	0,9150	0,2342	100	0,9400	0,2198

dengan VGG-16, parameter yang dihasilkan oleh ResNet-50 dengan ukuran citra masukan 224×224 piksel jauh lebih besar. Tabel III menunjukkan parameter dari model ResNet-50 yang diusulkan. Ukuran citra setelah dilakukan ekstraksi fitur adalah 7×7 dengan parameter sebanyak 23.587.712. Menggunakan tambahan lapisan yang sama dengan model VGG-16, ResNet-50 menghasilkan parameter pada setiap *dense layer* sebesar 51.380.736, 131.328, dan 514.

Setelah dilakukan pengujian ukuran citra dan *fine-tuning*, dilakukan pengujian *hyper parameter* dengan empat skenario, yaitu *optimizer* (Adam, SGD, dan RMSprop), *batch size* (32, 64, dan 128), *learning rate* (0,01, 0,001, dan 0,0001), dan *epoch* (10, 50, dan 100). Skenario pertama adalah *optimizer*, dengan *hyper parameter* lain yang telah ditentukan, yaitu *batch size* 64, *learning rate* 0,001, dan *epoch* 10. Tabel IV merangkum hasil pengujian model VGG-16 dan ResNet-50 pada keempat skenario. Skenario pertama pada model *optimizer* Adam VGG-16 memiliki kinerja yang lebih baik dibandingkan dengan SGD dan RMSprop pada model VGG-16. Lain halnya dengan model ResNet-50, yang mendapatkan kinerja terbaik pada penggunaan *optimizer* RMSprop, yaitu sebesar 0,9075.

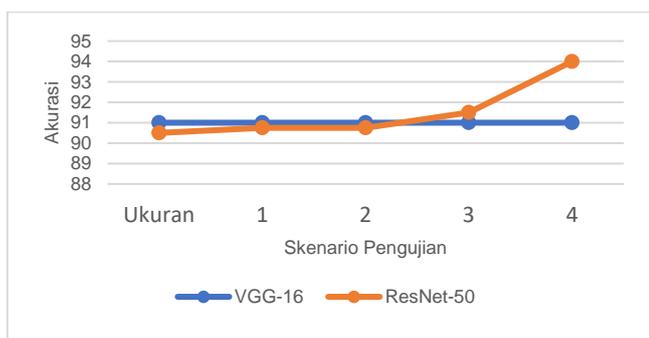
Hasil pengujian skenario kedua, yaitu *batch size* dengan *optimizer* yang berbeda, menunjukkan bahwa kedua model tidak mengalami peningkatan kinerja dari skenario yang sebelumnya. Hal ini berarti akurasi terbaik pada kedua model diberikan oleh *batch size* yang sama dengan yang telah ditentukan pada awal pengujian, yaitu 64. Skenario selanjutnya adalah pengujian *learning rate*, dengan nilai *learning rate* yang diuji adalah 0,01, 0,001, dan 0,0001. Skenario ini menghasilkan nilai *learning rate* berbeda pada kedua model. Model ResNet-50 memperoleh akurasi yang lebih baik daripada model VGG-16, yaitu dengan *learning rate* 0,0001 dan nilai akurasi sebesar 0,9150. Untuk model VGG-16, tidak terdapat perubahan akurasi dari skenario sebelumnya, yaitu dengan *learning rate* 0,001 dan akurasi 0,9100.

Setelah menguji *optimizer*, *batch size*, dan *learning rate*, dilakukan pengujian dengan skenario terakhir, yaitu pengujian *epoch*. Pada skenario keempat, dilakukan pengujian terhadap nilai *epoch* 10, 50, dan 100. Hasil yang diperoleh dari kedua

model berbeda, seperti yang ditunjukkan pada Tabel IV. Berdasarkan pengujian *epoch*, dapat disimpulkan bahwa pada model VGG-16, makin besar nilai *epoch*, makin menurun akurasi yang didapatkan, sehingga akurasi terbaiknya diperoleh pada saat *epoch* 10. Berbeda halnya dengan ResNet-50, yang memiliki kinerja terbaik pada *epoch* 100, yaitu dengan nilai akurasi 0,9400 dan *loss* 0,2198. Akurasi model ResNet-50 yang diperoleh lebih optimal dibandingkan penelitian sebelumnya yang menerapkan ukuran citra, *batch size*, dan *epoch* yang sama dan memperoleh akurasi 0,87 [33].

Setelah melewati pengujian dengan skenario yang sudah dijelaskan sebelumnya, didapatkan *hyper parameter* yang memberikan kinerja terbaik pada masing-masing model. Untuk model VGG-16, kinerja terbaik diberikan oleh citra dengan ukuran 128×128 piksel dengan *optimizer* Adam, *batch size* 64, *learning rate* 0,001, dan *epoch* 10. Hasil pengujian akurasi dan *loss* menggunakan data latih dan validasi dengan *hyper parameter* terbaik pada VGG-16 menunjukkan bahwa perbedaan akurasi pada data latih dan validasi tidak terlalu signifikan. Sementara itu, grafik *loss*-nya dapat diartikan bahwa *loss* dari data latih dan validasi tidak mengalami *overfitting* karena pada akhir *epoch*, grafik *loss* hampir tidak memberikan perbedaan yang berarti. Untuk model ResNet-50, kinerja terbaiknya diberikan pada citra dengan ukuran 224×224 piksel. *Hyper parameter* yang memberikan kombinasi terbaik untuk model ResNet-50 adalah *optimizer* RMSprop, *batch size* 64, *learning rate* 0,0001, dan *epoch* 100. Hasil pengujian pada data latih dan validasi pada grafik akurasi validasi setiap *epoch* relatif stabil, sedangkan grafik *loss* dapat dikatakan baik karena tidak menunjukkan perbedaan yang signifikan antara data latih dan validasinya.

Setelah kedua model dilatih menggunakan data latih dan validasi, dilakukan pengujian terhadap *dataset* baru, yaitu data uji dengan total 400 citra. Pengujian model menggunakan *dataset* uji menghasilkan nilai-nilai yang akan digunakan untuk mengukur kinerja model. Jumlah citra *benign* yang benar diklasifikasikan dalam kelas *benign* menggunakan model VGG-16 yaitu sebanyak 177 citra. Sementara itu, citra *malignant* yang diklasifikasikan benar sebagai kelas *malignant* berjumlah 187 citra. Untuk citra *benign* yang salah diprediksi



Gambar 5. Grafik akurasi terbaik pada setiap skenario.

TABEL V
 PERBANDINGAN DENGAN STATE-OF-THE-ART MODEL YANG DIUSULKAN

Teknik/Model	Dataset	Akurasi (%)
SVM and KNN [34]	Kaggle	70,61
Random forest [35]	Kaggle	84,20
CNN [33]	Kaggle	87,87
Transfer learning VGG-16 [6]	Kaggle dan HAM10000	88,00
Transfer learning VGG-16 [12]	Kaggle	89,09
Transfer learning VGG-16	Kaggle	91,00
Transfer learning ResNet-50	Kaggle	94,00

oleh model sebagai citra *malignant*, dan sebaliknya, citra *malignant* yang diprediksi sebagai citra *benign* oleh model, yaitu sebanyak 23 dan 13 citra. Tidak jauh berbeda dengan model VGG-16, model ResNet-50 memiliki nilai 185 dan 191 untuk citra yang diklasifikasikan sesuai pada kelas *benign* dan *malignant*. Sementara itu, jumlah citra *benign* yang salah diprediksi sebagai citra *malignant*, dan sebaliknya, citra *malignant* yang dianggap *benign* oleh model, adalah sebanyak 15 dan 9 citra. Dengan demikian, dapat dikatakan bahwa sebagian besar citra uji dapat diklasifikasikan sesuai dengan kelasnya.

Selain akurasi yang dihitung dengan (1), penghitungan kinerja juga dilakukan berdasarkan nilai presisi, sensitivitas, dan *f1-score*. Dengan menggunakan (2) sampai (4), diperoleh nilai rata-rata presisi, sensitivitas, dan *f1-score* pada VGG-16 sebesar 0,91. Hal ini menunjukkan bahwa model VGG-16 yang diusulkan dapat memberikan kinerja yang baik dalam mengklasifikasikan citra dermoskopi kanker kulit. Sementara itu, dapat dilihat bahwa model ResNet-50 dapat mengklasifikasikan citra lebih baik daripada model VGG-16. Pengukuran kinerja model ResNet-50 yang diusulkan menunjukkan bahwa nilai rata-rata presisi, sensitivitas, dan *f1-score* yang dihasilkan model ResNet-50 memiliki nilai sama, yaitu 0,94.

Hasil terbaik pada setiap skenario yang diuji dimodelkan dalam grafik pada Gambar 5. Setelah menerapkan skenario perubahan ukuran, dilakukan skenario 1, yaitu *optimizer*; skenario 2, yaitu *batch size*; skenario 3, yaitu *learning rate*; dan skenario 4, yaitu *epoch*. Dapat dilihat pada Gambar 5 bahwa untuk model VGG-16 tidak terdapat peningkatan akurasi dalam setiap skenarionya. Hal ini menunjukkan bahwa skenario *resize* dengan ukuran citra 128 × 128 piksel dan *hyper parameter tuning* yang telah ditentukan pada awal pengujian memberikan hasil terbaik. Lain halnya dengan model ResNet-50 yang hampir selalu mengalami peningkatan akurasi dalam setiap skenario yang diberikan, kecuali pada skenario 1 dan skenario 2, yaitu *optimizer* dan *batch size* yang memiliki nilai akurasi

terbaik yang sama. Oleh karena itu, skenario terakhir pada model ResNet-50 merupakan skenario yang memberikan akurasi optimal. Sementara itu, pada model VGG-16, akurasi terbaik telah didapatkan sejak skenario *resize*.

Perbandingan hasil kinerja model yang diusulkan dengan model lainnya disajikan pada Tabel V. Berdasarkan nilai akurasi, model yang diusulkan memberikan akurasi yang lebih baik dibandingkan dengan model lainnya yang menggunakan *dataset* sama, yaitu citra dermoskopi kanker kulit dari Kaggle yang mengklasifikasikan citra ke dalam dua kelas (*benign* dan *malignant*). Menggunakan model yang sama, yaitu VGG-16, penelitian ini memberikan kinerja lebih unggul berdasarkan hasil akurasi, yaitu 91%, dibandingkan penelitian sebelumnya, yaitu 89,09% [12]. *Dataset* yang sama, yaitu Kaggle dan HAM10000 telah diuji menggunakan *pre-trained VGG-16 model* dan ResNet-50 dan memberikan akurasi yang tidak berbeda secara signifikan, yaitu 88% untuk model VGG-16 dan 87% untuk model ResNet-50 [6]. Hasil akurasi tersebut diberikan oleh dua *dataset* yang berbeda, tetapi mempunyai nilai yang sama. Hal ini berarti bahwa kedua model yang diusulkan, VGG-16 dan ResNet-50, memberikan kinerja lebih baik. Selain itu, dengan menerapkan model ResNet-50 dan skenario *fine-tuning* yang sama, kecuali pada *Dense_3* digunakan fungsi aktivasi *sigmoid*, penelitian sebelumnya memberikan akurasi 87,87% pada *epoch* 150 [33]. Model ResNet-50 yang diusulkan pada penelitian ini menerapkan *epoch* yang lebih kecil, yaitu 100, dan menghasilkan kinerja terbaik dibandingkan model lainnya yang ada pada Tabel V, yaitu sebesar 94%.

IV. KESIMPULAN

Penelitian ini menggunakan teknik *deep transfer learning* dengan *pre-trained deep CNN* VGG-16 dan ResNet-50. Data latih, data validasi, dan data uji yang digunakan berasal dari *dataset* Kaggle. Model telah diuji menggunakan berbagai *hyper parameter* yang berbeda, yaitu *optimizer* yang terdiri atas Adam, SGD, dan RMSprop. Selain itu, model juga diuji dengan parameter *batch size* 32, 64, dan 128; *learning rate* 0,01, 0,001, dan 0,0001; serta *epoch* 10, 50, dan 100. Model yang diusulkan memberikan kinerja terbaiknya dengan akurasi 91% untuk model VGG-16 dan akurasi 94% untuk model ResNet-50. Masih terdapat banyak celah untuk meningkatkan akurasi dalam mengklasifikasikan citra kanker kulit. Dengan menggunakan *pre-trained model* yang berbeda, skenario *fine-tuning*, dan *hyper parameter tuning* lainnya, akurasi model dalam mengklasifikasikan citra kanker kulit akan dapat ditingkatkan.

KONFLIK KEPENTINGAN

Penulis menyatakan bahwa tidak terdapat konflik kepentingan pada artikel berjudul “*Deep Transfer Learning* untuk Meningkatkan Akurasi Klasifikasi pada Citra Dermoskopi Kanker Kulit”.

UCAPAN TERIMA KASIH

Terima kasih disampaikan kepada Direktorat Jenderal Pendidikan Islam Kementerian Agama Republik Indonesia dan semua pihak yang telah mendukung keberlangsungan penelitian ini.

REFERENSI

- [1] WHO (2022) “Cancer,” [Online], <https://www.who.int/news-room/fact-sheets/detail/cancer>, tanggal akses: 7-Jun-2022.
- [2] M.S. Ali dkk., “An Enhanced Technique of Skin Cancer Classification

- Using Deep Convolutional Neural Network with Transfer Learning Models,” *Mach. Learn. Appl.*, Vol. 5, hal. 1-8, Sep. 2021, doi: 10.1016/j.mlwa.2021.100036.
- [3] M.A. Kassem, K.M. Hosny, dan M.M. Fouad, “Skin Lesions Classification into Eight Classes for ISIC 2019 Using Deep Convolutional Neural Network and Transfer Learning,” *IEEE Access*, Vol. 8, hal. 114822–114832, Jun. 2020, doi: 10.1109/ACCESS.2020.3003890.
- [4] M.R. Hasan dkk., “Comparative Analysis of Skin Cancer (Benign vs. Malignant) Detection Using Convolutional Neural Networks,” *J. Healthc. Eng.*, Vol. 2021, hal. 1-17, Des. 2021, doi: 10.1155/2021/5895156.
- [5] P.P. Naik, “Cutaneous Malignant Melanoma: A Review of Early Diagnosis and Management,” *World J. Oncol.*, Vol. 12, No. 1, hal. 7–19, Feb. 2021, doi: 10.14740/wjon1349.
- [6] S. Bechelli dan J. Delhommelle, “Machine Learning and Deep Learning Algorithms for Skin Cancer Classification from Dermoscopic Images,” *Bioeng.*, Vol. 9, No. 3, hal. 1–18, Mar. 2022, doi: 10.3390/bioengineering9030097.
- [7] T.J. Brinker dkk., “Skin Cancer Classification Using Convolutional Neural Networks: Systematic Review,” *J. Med. Internet Res.*, Vol. 20, No. 10, hal. 1–8, Okt. 2018, doi: 10.2196/11936.
- [8] P.M.M. Pereira dkk., “Skin Lesion Classification Enhancement Using Border-Line Features – The Melanoma vs Nevus Problem,” *Biomed. Signal Process. Control*, Vol. 57, hal. 1-8, Mar. 2020, doi: 10.1016/j.bspc.2019.101765.
- [9] G. Argenziano dkk., “Dermoscopy Improves Accuracy of Primary Care Physicians to Triage Lesions Suggestive of Skin Cancer,” *J. Clin. Oncol.*, Vol. 24, No. 12, hal. 1877–1882, Apr. 2006, doi: 10.1200/JCO.2005.05.0864.
- [10] S.M. Jaisakthi, P. Mirunalini, dan C. Aravindan, “Automated Skin Lesion Segmentation of Dermoscopic Images Using GrabCut and K-Means,” *IET Comput. Vis.*, Vol. 12, No. 8, hal. 1088–1095, Des. 2018.
- [11] R. Agustina, R. Magdalena, dan N.K.C. Pratiwi, “Klasifikasi Kanker Kulit Menggunakan Metode Convolutional Neural Network dengan Arsitektur VGG-16,” *ELKOMIKA J. Tek. Energi Elektr. Tek. Telekomun. Tek. Elektron.*, Vol. 10, No. 2, hal. 446–457, Apr. 2022, doi: 10.26760/elkomika.v10i2.446.
- [12] V. Anand dkk., “An Enhanced Transfer Learning Based Classification for Diagnosis of Skin Cancer,” *Diagnostics*, Vol. 12, No. 7, hal. 1-18, Jul. 2022, doi: 10.3390/diagnostics12071628.
- [13] Y. Wu dkk., “Skin Cancer Classification with Deep Learning: A Systematic Review,” *Front. Oncol.*, Vol. 12, hal. 1–20, Jul. 2022, doi: 10.3389/fonc.2022.893972.
- [14] M.A. Kassem, K.M. Hosny, R. Damaševičius, dan M.M. Eltoukhy, “Machine Learning and Deep Learning Methods for Skin Lesion Classification and Diagnosis: A Systematic Review,” *Diagnostics*, Vol. 11, No. 8, hal. 1–29, Jul. 2021, doi: 10.3390/diagnostics11081390.
- [15] A. Saber dkk., “A Novel Deep-Learning Model for Automatic Detection and Classification of Breast Cancer Using the Transfer-Learning Technique,” *IEEE Access*, Vol. 9, hal. 71194–71209, Mei 2021, doi: 10.1109/ACCESS.2021.3079204.
- [16] R. Refianti, A.B. Mutiara, dan R.P. Priyandini, “Classification of Melanoma Skin Cancer Using Convolutional Neural Network,” *Int. J. Adv. Comput. Sci. Appl.*, Vol. 10, No. 3, hal. 409–417, Mar. 2019, doi: 10.14569/IJACSA.2019.0100353.
- [17] S. Saidah, I.P.Y.N. Suparta, dan E. Suhartono, “Modifikasi Convolutional Neural Network Arsitektur GoogLeNet dengan Dull Razor Filtering untuk Klasifikasi Kanker Kulit,” *J. Nas. Tek. Elekt., Teknol. Inf.*, Vol. 11, No. 2, hal. 148–153, Mei 2022, doi: 10.22146/jnteti.v11i2.2739.
- [18] H.A. Haenssle dkk., “Man Against Machine: Diagnostic Performance of a Deep Learning Convolutional Neural Network for Dermoscopic Melanoma Recognition in Comparison to 58 Dermatologists,” *Ann. Oncol.*, Vol. 29, No. 8, hal. 1836–1842, Agu. 2018, doi: 10.1093/annonc/mdy166.
- [19] T.J. Brinker dkk., “A Convolutional Neural Network Trained with Dermoscopic Images Performed on Par With 145 Dermatologists in a Clinical Melanoma Image Classification Task,” *Eur. J. Cancer*, Vol. 111, hal. 148–154, Apr. 2019, doi: 10.1016/j.ejca.2019.02.005.
- [20] S. Guan dan M. Loew, “Breast Cancer Detection Using Transfer Learning in Convolutional Neural Networks,” *2017 Appl. Imag. Pattern Recognit. Workshop (AIPR)*, 2017, hal. 1–8, doi: 10.1109/AIPR.2017.8457948.
- [21] M. Hussain, J.J. Bird, dan D.R. Faria, “A Study on CNN Transfer Learning for Image Classification,” dalam *Advances in Computational Intelligence Systems*, A. Lotfi dkk, Eds., Cham, Swiss: Springer Cham, 2019, hal. 191–202, 2019, doi: 10.1007/978-3-319-97982-3_16.
- [22] S. Tammina, “Transfer Learning Using VGG-16 with Deep Convolutional Neural Network for Classifying Images,” *Int. J. Sci. Res. Publ.*, Vol. 9, No. 10, hal. 143-150, Okt. 2019, doi: 10.29322/ijrsr.9.10.2019.p9420.
- [23] Shallu dan R. Mehra, “Breast Cancer Histology Images Classification: Training from Scratch or Transfer Learning?” *ICT Express*, Vol. 4, No. 4, hal. 247–254, Des. 2018, doi: 10.1016/j.icte.2018.10.007.
- [24] D.M. Wonohadidjojo, “Perbandingan Convolutional Neural Network pada Transfer Learning Method untuk Mengklasifikasikan Sel Darah Putih,” *Ultimics J. Tek. Inform.*, Vol. 13, No. 1, hal. 51–57, Jun. 2021, doi: 10.31937/ti.v13i1.2040.
- [25] Z. Aliyah, A. Arifianto, dan F. Sthevanie, “Classifying Skin Cancer in Digital Images Using Convolutional Neural Network with Augmentation,” *Indonesia J. Comput. (Indo-JC)*, Vol. 5, No. 2, hal. 55–66, Sep. 2020, doi: 10.21108/indojc.2020.5.2.455.
- [26] A. Abubakar, M. Ajuji, dan I.U. Yahya, “Comparison of Deep Transfer Learning Techniques in Human Skin Burns Discrimination,” *Appl. Syst. Innov.*, Vol. 3, No. 2, hal. 1–15, Apr. 2020, doi: 10.3390/asi3020020.
- [27] A.V. Ikechukwu, S. Murali, R. Deepu, dan R.C. Shivamurthy, “ResNet-50 vs VGG-19 vs Training from Scratch: A Comparative Analysis of the Segmentation and Classification of Pneumonia from Chest X-Ray Images,” *Glob. Transit. Proc.*, Vol. 2, No. 2, hal. 375–381, Nov. 2021, doi: 10.1016/j.gtlp.2021.08.027.
- [28] R.A. Khan, A. Crenn, A. Meyer, dan S. Bouakaz, “A Novel Database of Children’s Spontaneous Facial Expressions (LIRIS-CSE),” *Image Vis. Comput.*, Vol. 83–84, hal. 61–69, Mar.-Apr. 2019, doi: 10.1016/j.imavis.2019.02.004.
- [29] C. Nwankpa, W. Ijomah, A. Gachagan, dan S. Marshall, “Activation Functions: Comparison of Trends in Practice and Research for Deep Learning,” 2018, *arXiv*:1811.03378.
- [30] X. Qin dkk., “A Faster R-CNN Based Method for Comic Characters Face Detection,” *2017 14th IAPR Int. Conf. Doc. Anal., Recogn. (ICDAR)*, 2017, hal. 1074–1080, doi: 10.1109/ICDAR.2017.178.
- [31] M. Korpusik dan J. Glass, “Convolutional Neural Networks and Multitask Strategies for Semantic Mapping of Natural Language Input to a Structured Database,” *2018 IEEE Int. Conf. Acoust. Speech, Signal Process. (ICASSP)*, 2018, hal. 6174–6178, doi: 10.1109/ICASSP.2018.8461769.
- [32] E. Solovyeva dan A. Abdullah, “Binary and Multiclass Text Classification by Means of Separable Convolutional Neural Network,” *Inventions*, Vol. 6, No. 4, Okt. 2021, doi: 10.3390/inventions6040070.
- [33] K. Manasa dan D.G.V. Murthy, “Skin Cancer Detection Using VGG-16,” *Eur. J. Mol. Clin. Med.*, Vol. 8, No. 1, hal. 1419–1426, Jan. 2021.
- [34] M. Faruk dan N. Nafi’iyah, “Klasifikasi Kanker Kulit Berdasarkan Fitur Tekstur, Fitur Warna Citra Menggunakan SVM dan KNN,” *Telematika*, Vol. 13, No. 2, hal. 100–109, Agu. 2020, doi: 10.35671/telematika.v13i2.987.
- [35] N. Khasanah dkk., “Skin Cancer Classification Using Random Forest Algorithm,” *J. Ilm. Sisfotenika*, Vol. 11, No. 2, hal. 137–147, Jul. 2021, doi: 10.30700/jst.v11i2.1122.