

***Pattern Recognition untuk Klasifikasi Penyakit
Kanker Kulit menggunakan Artificial Intelligence (AI)***

**Sari Handayani Pusadan¹, Suriyanti², Andriar Makahrin³, Mohammad Yazdi⁴,
Zakiani Sakka⁵**

^{1,2,5} Fakultas Kedokteran, Pendidikan Dokter, Universitas Alkhairaat, Palu, Indonesia

^{3,4} Fakultas Teknik, Teknik Informatika, Universitas Tadulako, Palu, Indonesia

Email Penulis Korespondensi: sari.diyana@gmail.com

ABSTRAK

Penelitian ini bertujuan untuk mengimplementasikan metode kecerdasan buatan melalui algoritma Convolution Neural Network (C-NN) untuk mengklasifikasikan citra kanker kulit. Objek pada penelitian ini adalah klasifikasi kanker kulit dengan berdasarkan 7 kategori kanker kulit, sedangkan Data yang digunakan oleh peneliti adalah data yang bersumber dari The International Skin Imaging Collaboration (ISIC). Metode yang digunakan peneliti adalah Algoritma Convolutional Neural Networks (CNN). Pada data training dilakukan pembelajaran fitur, klasifikasi, dan optimum model, dimana proses ini merupakan implementasi algoritma yang digunakan. Skenario pengujian dengan indikator skenario pengujian yaitu pembagian data training 70%, 80%, dan 90%, inisialisasi Dropout layer bernilai 0.5, 0.6, dan 0.7, dan 0,8 dan Batchsize bernilai 8, 16, 32, 64. Kesimpulan dari Penelitian ini adalah mendapatkan model terbaik dengan nilai akurasi 83.22% dari komposisi data Taining 80%, Dropout 0.4 dan Batchsize 16.

Kata Kunci: Klasifikasi, InceptionV3; Convolutional Neural Network; Kanker Kulit

ABSTRACT

This research aims to classify skin cancer images using an artificial intelligence method called Convolutional Neural Networks (CNN). The study focuses on classifying skin cancer into 7 categories, using data from the International Skin Imaging Collaboration (ISIC). We employed the CNN algorithm to train the model, which involved learning features, classifying images, and optimizing the model. To evaluate the model's performance, we experimented with different training data proportions (70%, 80%, and 90%), dropout rates (0.5, 0.6, 0.7, and 0.8), and batch sizes (8, 16, 32, 64). The best results were achieved with 80% of the data for training, a dropout rate of 0.4, and a batch size of 16, resulting in an accuracy of 83.22%.

Keywords: Classification, InceptionV3, Convolutional Neural Network, Skin Cancer.

PENDAHULUAN

Kulit(Yuniarti and Anggraeni, 2018) merupakan organ tubuh terluar dan yang paling besar dari anatomi tubuh manusia. Kulit yang memiliki fungsi untuk melindungi bagian tubuh yang berada di bawahnya dari cedera dan patogen (Infeksi dari bakteri). Keindahan kulit menjadi faktor penting bagi setiap orang karena kulit yang indah mencerminkan kondisi kulit yang sehat. Hal ini dapat di tinjau dari warna kulit. Hal sederhana yang dilakukan untuk membuat kulit sehat adalah memberikan asupan sinar matahari di bawah pukul 9 pagi yang bermanfaat untuk menstimulus vitamin D kedalam kulit dan juga mengurangi infeksi jamur pada kulit. Namun sinar matahari yang berlebihan dapat mengakibatkan kulit terbakar (Sunburn) dan meningkatkan resiko kanker kulit. Radiasi ultraviolet B (UVB) yang memiliki efek langsung terhadap kulit

ketika dipaparkan secara berlebihan. Hal inilah yang akan merusak kulit dan menumbuhkan kanker pada kulit jika terpapar UVB secara berlebihan.

Kanker kulit (Nurlitasari, Magdalena and Fu'adah, 2022; Informatika *et al.*, 2023; Putra, Gunawan and Saragih, 2023; Schadendorf *et al.*, 2023) adalah salah satu jenis kanker yang serius dan belum dapat diobati. Pertumbuhan sel yang tidak normal menjadi diagnosis awal kanker kulit yang biasanya timbul pada area kulit yang sering terpapar sinar matahari namun, tidak menutup kemungkinan timbul di daerah jaringan kulit manapun pada bagian tubuh. Resiko kanker kulit pada umumnya terjadi pada rentang usia dibawah 40 tahun untuk wanita dan diatas 40 tahun untuk pria. Kanker kulit dapat diklasifikasikan kedalam tiga kategori yakni Karsinoma Sel Basal (KSB), Karsinoma Sel Skuamosa (KSS) dan Melanoma Maligna (MM) (Wilvestra, Lestari and Asri, 2018; Yahya *et al.*, 2021; Findry and Rizal Adi Saputra, 2024) Melanoma Maligna merupakan kanker kulit yang paling ganas yang berasal dari melanosit. Kanker jenis ini memiliki metastasis (penyebaran sel kanker) cukup tinggi sedangkan untuk dua kategori lainnya dapat disembuhkan dengan perawatan intensif. Di Indonesia, kanker kulit menempati urutan ketiga setelah kanker rahim dan kanker payudara. Tiga Kanker kulit dijumpai 5,9 – 7,8 % dari semua jenis kanker pertahun. Kanker kulit yang paling banyak di Indonesia adalah karsinoma sel basal (65,5%), diikuti karsinoma sel skuamosa (23%), melanoma maligna (7,9%) dan kanker kulit lainnya. Dalam bidang medis, untuk mendiagnosa penyakit kanker kulit dilakukan dengan pembedahan kecil untuk mengambil sebagian kecil jaringan kanker yang nantinya akan diperiksa di laboratorium menggunakan mikroskop atau biasa di sebut Biopsi (Nurlitasari, Magdalena and Fu'adah, 2022; Johannes and Al Rivan, 2022; Kosman, Wahyuningsih and Mahendrasusila, 2024), Invasif dan Mikroskopi. Diagnosa Biopsi ini untuk penentuan akhir jaringan tersebut kanker atau bukan dan kanker jinak atau ganas. Karena pemeriksaan ini butuh ketelitian dan waktu yang cukup lama bahkan untuk pakar dermatologis ahli dan biopsi ini memiliki risiko nyeri dan juga kesemutan pada area biopsi. Selain itu juga tindakan biopsi memerlukan biaya yang cukup mahal serta dapat melukai atau menggores kulit manusia. Convolutional Neural Network (C-NN) (Minarno *et al.*, 2022) (Budiarto Hadiprakoso and Buana, 2021) (Luqman Hakim, Sari and Handhajani, 2021) adalah salah satu algoritma deep learning yang digunakan untuk kasus-kasus penggunaan computer vision seperti mengklasifikasikan gambar atau video dan mendeteksi objek di dalam gambar atau bahkan wilayah dalam gambar.

C-NN mengalami perkembangan dengan beberapa variasi arsitektur seperti Le Net, AlexNet (Al Rivan and Riyadi, 2021; Mousavi and Farahani, 2022), GoogLeNet, ResNet, dan lainnya. GoogleNet merupakan arsitektur dari metode CNN yang dikenalkan pada tahun 2014 dan memenangkan kompetisi ImageNet Large-Scale Visual Recognition Challenge 2014 (ILSVRC14) untuk klasifikasi data citra. Arsitektur GoogleNet yang populer ini sudah digunakan peneliti sebelumnya. Penelitian yang dilakukan oleh Nurul Fathanah Mustamin membandingkan arsitektur C-NN yakni GoogleNet, Alexnet, Resnet101, Resnet18 dan Resnet50 untuk klasifikasi kualitas kayu kelapa menggunakan citra ukuran 255x255 piksel. Hasil akurasi tertinggi diperoleh arsitektur GoogleNet dengan nilai 84,89%.

METODOLOGI PENELITIAN

Kanker Kulit, merupakan kelainan pada pada jaringan kulit yang dapat di amati dengan adanya pertumbuhan sel kulit secara abnormal terutama bagian kulit yang sering terkena matahari berlebih. Berdasarkan asal selnya kanker kulit dikategorikan menjadi dua kategori yakni Non-Melanoma Skin Cancer (NMSC) dan Melanoma Skin Cancer (MSC). Kanker kulit non-melanoma terdiri dari dua jenis yaitu Bassal Cell Carcinoma

(BCC) dan Squamous Cell Carcinoma (SCC). ketiga jenis kanker kulit tersebut diuraikan sebagai berikut:

Bassal Cell Carcinoma (BCC)

Bassal Cell Carcinoma (BCC)(Khan *et al.*, 2022) merupakan jenis kanker kulit yang ditandai dengan kemunculan benjolan yang rentan berdarah yang biasanya tumbuh sekitaran jaringan kulit yang terpapar sinar matahari dan juga terjadi pada manusia berusia lanjut. Kanker kulit yang paling banyak didapat ialah kanker kulit dengan jenis karsinoma sel basal (87,5%).

Squamous Cell Carcinoma (SCC)

Squamous Cell Carcinoma (SCC)(Wibawa *et al.*, 2019) adalah tumor ganas kulit nonmelanoma yang berasal dari keratinosit suprabasal epidermis. seperti pada BCC, salah satu faktor penyebab SCC adalah pajanan radiasi ultraviolet diketahui merupakan salah satu pemicu utama sehingga tempat predileksi keganasan ini adalah area yang sering terpajan sinar matahari, terutama kepala dan leher. tentunya ada beberapa faktor lain seperti karena sedang menderita infeksi human papillomavirus (HPV), adanya kelainan genetik dan imunitas rendah.

Melanoma

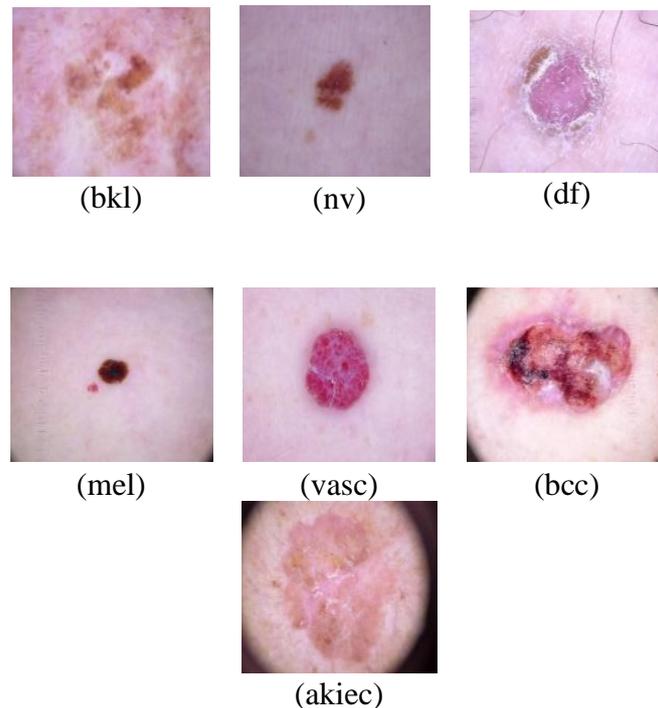
Melanoma(Hasan *et al.*, 2023) adalah tumor ganas dari sel melanosit dan terutama terjadi di kulit [10]. Melanoma dapat di induksi melalui berbagai mekanisme, seperti tekanan pada sistem kekebalan kulit, induksi sel melanosit, produksi radikal bebas, dan kerusakan DNA melanosit. Melanoma merupakan kanker kulit paling berbahaya dan mematikan dibandingkan BCC dan SCC dan menyumbang 90% dari kematian terkait tumor kulit [11]. Adapaun faktor resiko paling umum adalah pajanan sinar matahari/radiasi UV, dan varian reseptor melanokortin-1 yang diwariskan secara genetik.

Pada penelitian ini menggunakan data penelitian yang bersumber dari dari International Skin Imaging Collaboration Archive (ISIC) yang telah dikumpulkan dan dikelompokan berdasarkan metadata berformat .jpg dan .csv. Data tersebut dipublikasi dalam bentuk zip pada website kaggle. Data yang digunakan berjumlah 10.015 data gambar yang terbagi dalam 7 kelas yang diuraikan pada tabel 1.

Tabel 1. Data kanker kulit

No	Nama	Nama Kelas	Jumlah data
1.	Keratosis jinak berpigmen	bkl	1099
2.	Nevi melanosit	nv	6705
3.	Dermatofibroma	df	115
4.	Melanoma	mel	1113
5.	Lesi vaskular	vasc	142
6.	karsinoma sel basal	bcc	514
7.	keratosis aktinik	akiec	327
Total Citra Gambar			10015

Sampel dari masing-masing kelas yang terdapat pada tabel 1, dapat dilihat pada gambar 1.



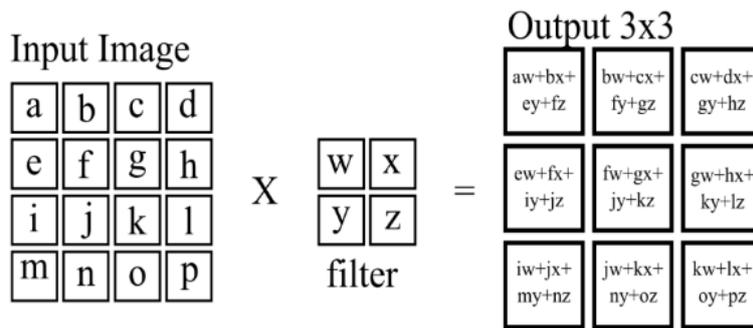
Gambar 1. Sampel citra kanker kulit

Convolutional Neural Network (CNN)

Convolutional Neural Network (C-NN) termasuk kedalam deep neural network karena kompleksitas jaringan yang terbangun dalam algoritma ini. Convolutional Neural Network (C-NN) adalah pengembangan dari Multilayer Perceptron (MLP) yang didesain untuk mengolah data dua dimensi. Algoritma Convolutional Neural Network lebih banyak di implementasikan pada pengolahan data citra. Beberapa tahun belakangan ini C-NN menjadi algoritma yang cukup populer untuk mengolah citra data medis rumit karena kompleksitas algoritma C-NN yang tinggi dan akurasi yang bekerja seperti visual cortex manusia. Algoritma C-NN umumnya terbagi atas tiga layer yakni input layer, hidden layer dan output layer. Didalam hidden layer terdapat beberapa metode yang digunakan oleh peneliti seperti convolutional Layer, Rectified Linear Unit (ReLU), local response normalization layer, Pooling Layer, drop out layer dan Fully Connected Layer.

Convolutional layer

Convolutional layer (Anjani, Pratiwi and Norfa Bagas Nurhuda, 2021) adalah proses matematis untuk mengolah nilai piksel dalam gambar inputan. Matriks yang merupakan bentuk dari convolution layer di implementasikan kedalam dua bentuk matriks yaitu matriks citra input dan matriks kernel atau filter. Output yang didapat pada proses di *convolution layer* berupa tumpukan feature map dari semua lapisan filter. Proses konvolusi secara sederhana dapat dilihat pada gambar 2 dibawah ini.



Gambar 2. Operasi konvolusi

Proses akhir dari convolutional layer adalah feature map seperti pada persamaan (1).

$$h = \frac{i - k + 2p}{s} \quad (1)$$

Keterangan:

h adalah dimensi *feature map*

k adalah dimensi filter

p adalah dimensi padding

s adalah jumlah *stride*

Rectified Linear

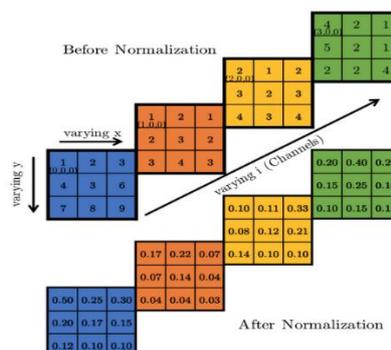
Rectified Linear Unit (ReLU)(Mao and Zhou, 2023; Findry and Rizal Adi Saputra, 2024) secara konvensional digunakan sebagai fungsi aktivasi untuk hidden layer di dalam jaringan saraf. Misalkan x adalah nilai input maka fungsi aktivasi ReLU dapat didefinisikan pada Persamaan (2).

$$F(x) = \max(0, x) \quad (2)$$

Dimana ReLU pada intinya hanya membuat pembatas pada bilangan nol, artinya apabila $x \leq 0$ maka $x = 0$ dan apabila $x > 0$ maka $x = x$.

Local response normalization layer

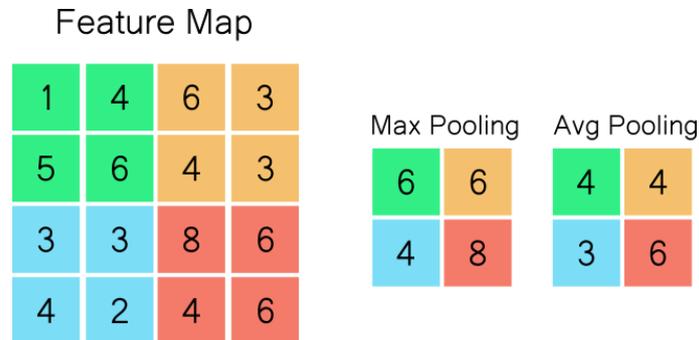
Local response normalization layer(Rahman *et al.*, 2024) biasa juga disebut sebagai *Cross Channel Normalization* berfungsi untuk mengatasi perbedaan nilai piksel yang signifikan pada citra input. Normalisasi berperan penting dalam algoritma C-NN untuk mengatasi nilai yang tidak dibatasi pada fungsi aktivasi ReLU. Ilustrasi layer normalisasi ini dapat ditunjukkan pada gambar 3.



Gambar 3. Ilustrasi perhitungan local response normalization layer

Pooling layer

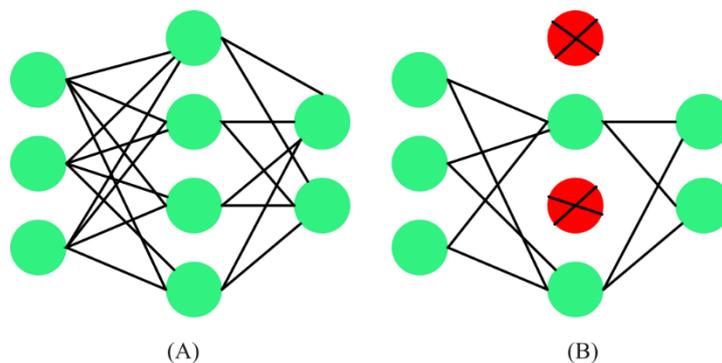
Pooling layer (Zafar *et al.*, 2022) adalah lapisan yang memanfaatkan fungsi feature map sebagai masukan yang berdasarkan atas nilai piksel terdekat. Proses pooling mempunyai dua mekanisme pooling diantaranya max pooling dan average pooling.



Gambar 4. Pooling layer

Dropout Layer

Dropout Layer (Minarno *et al.*, 2022) merupakan salah satu usaha untuk mencegah terjadinya overfitting dan juga mempercepat proses learning. Perhatikan gambar 5 dibawah ini.



Gambar 5. Contoh tanpa dropout layer, (B) menggunakan dropout layer

Dropout akan menghilangkan jaringan neuron dari hidden layer dan juga layer yang tampak secara acak. Hal ini akan meningkatkan performa model yang dilatih.

Fully Connected Layer

Lapisan *Fully Connected Layer* (Luqman Hakim, Sari and Handhajani, 2021) biasanya digunakan pada metode *Multi-Layer Perceptron* (MLP) dan bertujuan untuk mengolah data sehingga bisa diklasifikasikan. Data yang akan di klasifikasikan bersumber dari ouput convolutional layer dan pooling layer. Dimana dapat diartikan bahwa Setiap jaringan pada fully connected layer saling terhubung dengan jaringan pada lapisan sebelumnya. Output yang dihasilkan dari pooling layer masih berbentuk multidimensional array, sehingga akan di-flatten terlebih dahulu untuk mengubah data menjadi vektor sebelum dijadikan input untuk fully connected layer. Fully connected layer bekerja pada tiga hidden layer yakni Action Function, Output Layer dan Loss Function. Fully connected layer tidak menggunakan operasi convolution untuk mendapatkan keluaran dari layer tersebut, tapi menggunakan perkalian matriks. Secara umum keluaran pada Fully connected layer dapat ditentukan pada Persamaan (3).

$$h(x) = g(b + \sum_i w_i x_i) \quad (3)$$

Dimana g adalah fungsi aktivasi, b sebagai bias, w_i merupakan nilai masukan, dan x_i adalah nilai bobot.

GoogleNet

GoogleNet(Gayathri *et al.*, 2023) merupakan arsitektur yang dicetuskan oleh Google pada tahun 2014. Dalam ajang kompetisi ImageNet Large Scale Visual Recognition Challenge (ILSVRC) 2014 arsitektur ini menduduki posisi pertama sebagai arsitektur dengan kinerja terbaik. Arsitektur ini bekerja dengan mendeteksi citra dengan lapisan yang dimiliki sejumlah 5 hingga 22 lapisan, tetapi tetap memiliki akurasi yang tinggi. Keunggulan pada arsitektur GoogleNet terdapat pada Inception modules yang terinspirasi dari model visual cortex pada manusia yang berfungsi untuk menerima, mengintegrasikan, dan memproses informasi visual yang disampaikan dari retina. Inception modules terdiri dari beberapa convolution kecil yang bertujuan untuk mereduksi jumlah parameter tanpa mengurangi kinerja jaringan. Dalam penelitian ini menggunakan InceptionV3 yang berisi lebih banyak lapisan dengan efisiensi lebih baik daripada versi sebelumnya. Berikut model arsitektur dari InceptionV3 dapat dilihat pada tabel 2.

Tabel 2. Arsitektur dari InceptionV3

Type	Patch / stride size	Input Size
Conv	3×3/2	299×299×3
Conv	3×3/1	149×149×32
Conv padded	3×3/1	147×147×32
Pool	3×3/2	147×147×64
Conv	3×3/1	73×73×64
Conv	3×3/2	71×71×80
Conv	3×3/1	35×35×192
3 × Inception	Module 1	35×35×288
5 × Inception	Module 2	17×17×768
2 × Inception	Module 3	8×8×1280
Pool	8 × 8	8 × 8 × 2048
Linear	Logits	1 × 1 × 2048
Softmax	Classifier	1 × 1 × 1000

Berdasarkan Tabel diatas dapat diuraikan sebagai berikut: **Input Layer**(Luqman Hakim, Sari and Handhajani, 2021), gambar input memiliki dimensi 299x299 piksel dengan 3 saluran warna (RGB).

Convolutional Layers(Anjani, Pratiwi and Norfa Bagas Nurhuda, 2021), Conv 3x3/2 Lapisan konvolusi pertama dengan kernel 3x3 dan stride 2. Ini mengurangi ukuran gambar menjadi setengahnya sambil mengekstrak fitur dasar. Conv 3x3/1 Lapisan konvolusi kedua dengan kernel 3x3 dan stride 1. Ini meningkatkan jumlah fitur tanpa mengubah ukuran gambar. Conv padded 3x3/1 Lapisan konvolusi ketiga dengan kernel 3x3, stride 1, dan padding untuk mempertahankan ukuran gambar. Pool 3x3/2 Lapisan pooling dengan kernel 3x3 dan stride 2 untuk mengurangi ukuran gambar dan memperkuat fitur. Conv 3x3/1, Conv 3x3/2, Conv 3x3/1 Beberapa lapisan konvolusi tambahan dengan kernel 3x3 dan stride yang berbeda untuk ekstraksi fitur lebih lanjut.

Inception Modules(Nagpal and Dubey, 2019), tiga kali *Inception Module 1* Tiga modul Inception pertama, yang masing-masing terdiri dari beberapa cabang konvolusi dengan ukuran kernel berbeda (1x1, 3x3, 5x5) dan pooling. 5x *Inception Module 2* Lima modul Inception kedua dengan struktur yang lebih kompleks. 2x *Inception Module 3* Dua modul Inception terakhir, yang semakin meningkatkan kompleksitas fitur yang diekstrak.

Output Layer(Sitepu and Sigiro, 2021), Pool 8x8 Lapisan pooling dengan kernel 8x8 untuk mereduksi fitur menjadi vektor tunggal. Linear Lapisan fully connected untuk melakukan klasifikasi dengan 2048 neuron. Softmax Lapisan softmax untuk menghasilkan probabilitas kelas untuk setiap gambar input.

Confusion Matrix Multi-class, confusion matrix(Mohammad Yazdi Pusadan *et al.*, 2022; Paraijun, Aziza and Kuswardani, 2022) merupakan salah satu metode yang dapat digunakan untuk mengukur kinerja suatu metode klasifikasi. Confusion matrix berukuran LxL, dimana L adalah jumlah label klasifikasi yang berbeda. Confusion matrix menentukan akurasi yang didapat dari nilai beberapa parameter, seperti True Positif (TP), False Positif (FP), True Negatif (TN), dan False Negatif (FN). Tabel Confusion Matrix Multi Class dapat dilihat pada tabel 3.

Tabel 3. Confusion Matrix Multi Class

Kelas Aktual	Kelas 1	Kelas 2	Kelas 3	Kelas 4	Kelas 5
Kelas 1	TP11	FP12	FN13	FP14	FP15
Kelas 2	FP21	TP22	FP23	FN24	FP25
Kelas 3	FN31	FP32	TP33	FP34	FN35
Kelas 4	FP41	FN42	FP43	TP44	FP45
Kelas 5	FP51	FP52	FN53	FP54	TP55

Keterangan:

- True Positive (TP), Jumlah data positive yang benar diklasifikasi oleh classifier
- True Negative (TN), Jumlah data negative yang benar diklasifikasi oleh classifier.
- False Positive (FP), Jumlah data negative yang salah diklasifikasi sebagai data positive.
- False Negative (FN), jumlah data positive yang salah diklasifikasi sebagai data negative.

Dari tabel 3 penulis menggunakan beberapa metrik kinerja model berdasarkan *Weighted Average* seperti *Accuracy*, *Precision*, *Recall* dan *F1- Score*.

HASIL DAN PEMBAHASAN

Hasil yang dicapai dari penelitian ini adalah model terbaik berdasarkan evaluasi dalam skenario pengujian. Skenario pengujian yang digunakan dalam penelitian ini berupa nilai Batchsize, presentase pembagian data, dan dropout layer. Sebelum model dibangun, data yang telah dikumpulkan akan di augmentasi untuk meningkatkan performa model nantinya. Augmentasi data yang digunakan zoom range, shift range dan rotation range. Setelah data telah melalui proses pra-processing maka langkah selanjutnya adalah membangun model klasifikasi yakni menggunakan arsitektur googlenet (*InceptionV3*) yang model ini telah terlatih sebelumnya pada dataset imagenet sehingga dapat mengurangi waktu komputasi dan meningkatkan performa. Karena model dasar *InceptionV3* dari dataset imagenet maka bobot dari layer awal dibekukan. Hal ini dilakukan untuk mengurangi overfitting. Kemudian layer akhir *InceptionV3* dibuang dan digantikan dengan layer klasifikasi, seperti: **Dropout**, layer ini untuk mencegah overfitting dengan cara menonaktifkan neuron secara acak pada tiap iterasi training.

Dense Layer, lapisan penuh dengan 128 neuron dan fungsi aktivasi ReLU untuk menambahkan non-linearitas ke model

Dense Layer terakhir, lapisan penuh dengan jumlah neuron sesuai dengan jumlah kelas keluaran (tipe lesi) dan fungsi aktivasi softmax untuk menghasilkan probabilitas untuk tiap kelas keluaran. Kemudian pelatihan model dilakukan dengan setiap data training akan dicacah menjadi kumpulan batch kecil dan akan dimasukkan kedalam model melalui proses forward propagation kedalam hidden layer yang nantinya akan menghasilkan output dari model. Jika terdapat error maka akan diproses menggunakan backward propagation untuk memperbaharui bobot model agar mendapatkan hasil prediksi yang lebih baik pada iterasi selanjutnya. Memperbaharui bobot ini menggunakan fungsi adam sebagai fungsi optimizer selama proses training. Setelah menjalani proses training data maka model akan dievaluasi untuk memuat model terbaik selama proses training. Evaluasi yang dilakukan dengan menghitung nilai accuracy. Kemudian akan dilakukan visualisasi data berupa Confusion Matrix multi kelas dan Weighted Average dari precision, re-call, f1-score. Permodelan ini terus dilakukan untuk mendapatkan hasil model terbaik sesuai dengan skenario pengujian yang telah disebutkan sebelumnya.

Dalam klasifikasi citra untuk mendeteksi kanker kulit menggunakan algoritma CNN Inception V3 dapat dipengaruhi beberapa faktor antara lain jumlah data, kualitas citra, keberagaman data, presentasi pembagian data training dan testing, dropout dan batch size untuk mendapatkan performa model terbaik dan efisien. Dalam penelitian ini pembagian data training dan testing yang diterapkan adalah 70%, 80% dan 90%. Dropout bernilai 0.4, 0.5, 0.6 dan 0.7 serta nilai dari Batchsize yang dilakukan skenario pengujian bernilai 8, 16, 32 dan 64.

Tahapan pelatihan dan pengujian pada penelitian ini menggunakan Google Colab dengan Tensor Processing Unit (TPU). Hasil pengujian dari skenario yang telah dibuat dapat dilihat pada Tabel 4, 5 dan 6.

Tabel 4. Pengujian Dengan Pembagian Data Training 70%

Data latih	Dropout	Batchsize	Akurasi (%)
70%	0.4	8	81.99
		16	80.66
		32	80.08
		64	81.44
	0.5	8	81.39
		16	80.78
		32	80.28
		64	80.56
	0.6	8	80.73
		16	80,10
		32	80.26
		64	79.32
	0.7	8	80.64
		16	80.18
		32	80.12
		64	80.34

Tabel 5. Pengujian dengan pembagian data training 80%

Data latih	Dropout	Batchsize	Akurasi (%)
80%	0.4	8	82.68
		16	83.22

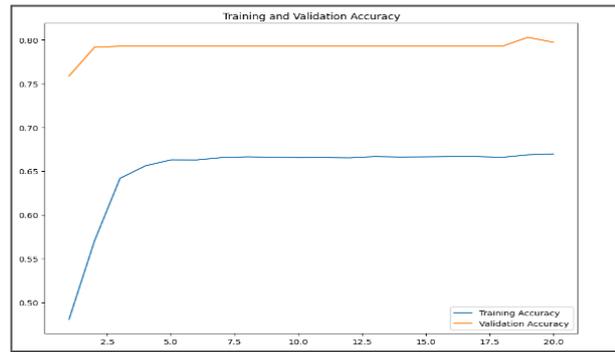
Data latih	Dropout	Batchsize	Akurasi (%)
		32	81.12
		64	81.41
		8	80
	0.5	16	81.41
		32	82.28
		64	81.08
		8	79.70
	0.6	16	80,63
		32	80.05
		64	79,68
		8	79,50
	0.7	16	82,99
		32	80,12
		64	80,44

Tabel 6. Pengujian dengan pembagian data training 90%

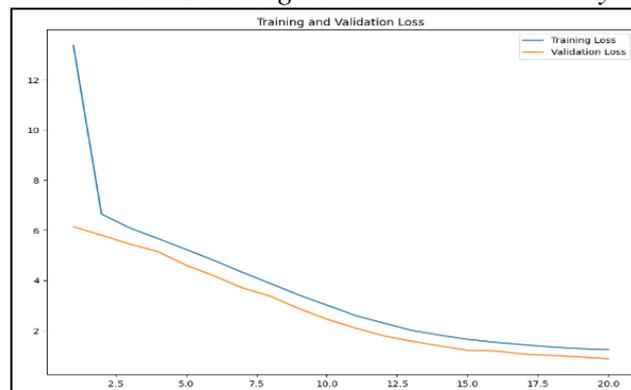
Data latih	Dropout	Batchsize	Akurasi (%)
		8	82.25
	0.4	16	80.12
		32	79.12
		64	80.41
		8	82.79
	0.5	16	80.26
		32	79.22
		64	79.68
90%		8	80.24
	0.6	16	80,13
		32	80.00
		64	79,08
		8	80,12
	0.7	16	80,19
		32	79,32
		64	79,68

Berdasarkan tabel 4, 5 dan 6 maka model terbaik didapatkan dari Akurasi tertinggi dengan parameter data latih 80%, dropout bernilai 0.4 dan batchsize bernilai 16 dengan akurasi yang dihasilkan oleh model adalah 83.22%.

Training progress pada model terbaik dapat dilihat pada Gambar 6 dan Gambar 7.



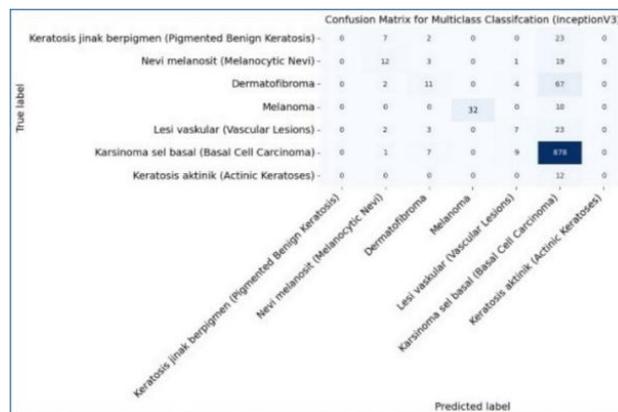
Gambar 6. Training dan validation accuracy



Gambar 7. Training dan validation loss

Pada Gambar 6 Grafik berwarna kuning menunjukkan peningkatan akurasi dataset validasi sedangkan grafik biru menunjukkan peningkatan akurasi dataset training. Pada iterasi ke 2 hingga 17 grafik menunjukkan tidak adanya penurunan dan peningkatan model namun pada iterasi ke 18 model meningkat dan berakhir turun pada iterasi ke 20. Sedangkan Gambar 7 Grafik berwarna kuning menunjukkan validation loss sedangkan grafik biru menunjukkan training loss. Dilihat pada grafik model validation loss dan training loss semakin menurun pada setiap iterasi hal ini menunjukkan model 59ambara dengan baik dari dataset training dan dapat menggeneralisasi dengan baik pada data baru.

Dari progress training yang ditunjukkan pada gambar 6 dan 7 maka dapat divisualisasikan performa model terbaik kedalam *Confusion Matrix Multi Class*. *Confusion Matrix multi class* pada Gambar 8 memberikan 59ambaran lebih detail tentang kesalahan klasifikasi yang dilakukan oleh model. Dengan menganalisis matriks ini, dapat mengidentifikasi kelas mana yang sulit dibedakan oleh model.



Gambar 8. Confusion matrix multi-class

Confusion Matrix Multi Class pada gambar 8 model banyak mendeteksi pada kelas karsinoma sel basal karena kelas tersebut adalah kelas mayoritas dari dataset yang ada. Sedangkan pada kelas keratosis aktinik model sangat lemah dalam klasifikasi. Dari gambar tersebut dapat diperoleh nilai *accuracy*, *precision*, *recall* dan *F1- Score* yang dapat dilihat tabel 7.

Tabel 7. Parameter Performa

Accuracy	Precision	recall	F1- Score
83.22%	89%	88%	86%

Nilai yang terdapat pada tabel 7 diperoleh dari perhitungan bobot tiap kelas menggunakan metode *Weighted Average*. Interpretasi hasil dari tabel adalah nilai *precision* yang tinggi menunjukkan bahwa model jarang membuat prediksi positif yang salah. Dalam kasus ini, model memiliki *precision* yang tinggi untuk beberapa kelas, seperti *Nevi melanosit*, *Melanoma*, dan *Karsinoma sel basal (Basal Cell Carcinoma)*. Sedangkan nilai *recall* yang tinggi menunjukkan bahwa model jarang melewatkan kasus positif yang sebenarnya ada. Dalam kasus ini, model memiliki *recall* yang tinggi untuk beberapa kelas, seperti *Keratosis jinak berpigmen (Pigmented Benign Keratosis)*, *Nevi melanosit (Melanocytic Nevi)*, dan *Karsinoma sel basal (Basal Cell Carcinoma)*.

SIMPULAN

Berdasarkan hasil pemodelan klasifikasi dengan memperhatikan tujuan penelitian maka didapat kesimpulan Pada penelitian ini dibangun sebuah model klasifikasi kanker kulit menggunakan metode deep learning dengan penerapan algoritma CNN dan arsitektur Googlenet (Inception V3) yang memiliki beberapa tahap penting yaitu pre-processing yang terdiri dari rotation range, zoom range dan shift range. Augmentasi ini berguna untuk model dapat belajar lebih baik, data bervariasi dan tidak mudah overfitting. Model yang dibangun menggunakan inceptionV3 yang sudah terlatih sebelumnya pada dataset imagenet dengan membekukan kumpulan layer dasarnya. Hal ini berarti bobot pada layer-layer tersebut tidak akan diubah selama proses training model klasifikasi penyakit kulit. Model kemudian diuji dengan skenario pengujian berdasarkan nilai batchsize, dropout dan pembagian data training. Adapun parameter yang digunakan untuk data training adalah random state 80 dan 600, fungsi loss dan optimizer, dan Early Stopping. Berdasarkan skenario pengujian, maka didapatkan model terbaik dengan nilai akurasi 83.22% menunjukkan bahwa dari keseluruhan data uji, model bisa memprediksi kategori lesi kulit dengan benar, *precision* 89% menunjukkan bahwa ketika model memprediksi suatu kategori lesi kulit, model dapat melakukan klasifikasi 89% dari prediksi yang benar dan *recall* 88% menunjukkan bahwa dari keseluruhan kasus lesi kulit yang sebenarnya ada, model mampu mengidentifikasi dengan benar sebanyak 88%.

UCAPAN TERIMA KASIH

Penulis mengucapkan terima kasih kepada Lembaga Penelitian dan Pengabdian Universitas Alhairaat Palu yang telah memberikan bantuan dana dalam penelitian ini. Penelitian ini didanai melalui Pembiayaan Hibah Internal Tahun 2024. Penulis juga mengucapkan terima kasih kepada beberapa pihak yang mendukung ketersediaan data selama penelitian berlangsung.

DAFTAR PUSTAKA

Anjani, I.A., Pratiwi, Y.R. and Norfa Bagas Nurhuda, S. (2021) 'Implementation of Deep Learning Using Convolutional Neural Network Algorithm for Classification Rose Flower', *Journal of Physics: Conference Series*, 1842(1). Available at:

- <https://doi.org/10.1088/1742-6596/1842/1/012002>.
- Budiarto Hadiprakoso, R. and Buana, I.K.S. (2021) 'Deteksi Serangan Spoofing Wajah Menggunakan Convolutional Neural Network', *Jurnal Teknik Informatika dan Sistem Informasi*, 7(3), pp. 618–626. Available at: <https://doi.org/10.28932/jutisi.v7i3.4001>.
- Findry, F. and Rizal Adi Saputra (2024) 'Klasifikasi Kanker Kulit Berdasarkan Data Citra Benign Dan Malignant Menggunakan Convolutional Neural Network', *Jurnal Mahasiswa Teknik Informatika*, 3(1), pp. 1–9. Available at: <https://doi.org/10.35473/jamastika.v3i1.2417>.
- Gayathri, P. *et al.* (2023) 'Exploring the Potential of VGG-16 Architecture for Accurate Brain Tumor Detection Using Deep Learning', *Journal of Computers, Mechanical and Management*, 2(2), pp. 1–10. Available at: <https://doi.org/10.57159/gadl.jcmm.2.2.23056>.
- Hasan, N. *et al.* (2023) 'Skin cancer : understanding the journey of transformation from conventional to advanced treatment approaches', *Molecular Cancer*, pp. 1–71. Available at: <https://doi.org/10.1186/s12943-023-01854-3>.
- Informatika, P.S. *et al.* (2023) 'KLASIFIKASI JENIS KANKER KULIT MANUSIA', pp. 144–150.
- Khan, N.H. *et al.* (2022) 'Skin cancer biology and barriers to treatment: Recent applications of polymeric micro/nanostructures', *Journal of Advanced Research*, 36, pp. 223–247. Available at: <https://doi.org/10.1016/j.jare.2021.06.014>.
- Kosman, A.W., Wahyuningsih, Y. and Mahendrasusila, F. (2024) 'Penguujian Metode Inception V3 dalam Mengidentifikasi Penyakit Kanker Kulit', *Jurnal Teknologi Informatika dan Komputer*, 10(1), pp. 132–142. Available at: <https://doi.org/10.37012/jtik.v10i1.1940>.
- Luqman Hakim, Sari, Z. and Handhajani, H. (2021) 'Klasifikasi Citra Pigmen Kanker Kulit Menggunakan Convolutional Neural Network', *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 5(2), pp. 379–385. Available at: <https://doi.org/10.29207/resti.v5i2.3001>.
- Mao, T. and Zhou, D.X. (2023) 'Rates of approximation by ReLU shallow neural networks', *Journal of Complexity*, 79, p. 101784. Available at: <https://doi.org/10.1016/j.jco.2023.101784>.
- Minarno, A.E. *et al.* (2022) 'Convolutional Neural Network featuring VGG-16 Model for Glioma Classification', *INTERNATIONAL JOURNAL ON INFORMATICS VISUALIZATION*, 6(September), pp. 660–666. Available at: www.joiv.org/index.php/joiv.
- Mohammad Yazdi Pusadan *et al.* (2022) 'k-Nearest Neighbor and Feature Extraction on Detection of Pest and Diseases of Cocoa', *Jurnal RESTI (Rekayasa Sistem dan Teknologi Informasi)*, 6(3), pp. 471–480. Available at: <https://doi.org/10.29207/resti.v6i3.4064>.
- Mousavi, S. and Farahani, G. (2022) 'A Novel Enhanced VGG16 Model to Tackle Grapevine Leaves Diseases With Automatic Method', *IEEE Access*, 10(September), pp. 111564–111578. Available at: <https://doi.org/10.1109/ACCESS.2022.3215639>.
- Nagpal, C. and Dubey, S.R. (2019) 'A Performance Evaluation of Convolutional Neural Networks for Face Anti Spoofing', *Proceedings of the International Joint Conference on Neural Networks*, 2019-July, pp. 1–8. Available at: <https://doi.org/10.1109/IJCNN.2019.8852422>.
- Nurlitasari, D.A., Magdalena, R. and Fu'adah, R.Y.N. (2022) 'Analisis Performansi Sistem Klasifikasi Kanker Kulit Menggunakan Convolutional Neural Network', *Journal of Electrical and System Control Engineering*, 5(2), pp. 91–99. Available

- at: <https://doi.org/10.31289/jesce.v5i2.5691>.
- Paraijun, F., Aziza, R.N. and Kuswardani, D. (2022) 'Implementasi Algoritma Convolutional Neural Network Dalam Mengklasifikasi Kesegaran Buah Berdasarkan Citra Buah', *Kilat*, 11(1), pp. 1–9. Available at: <https://doi.org/10.33322/kilat.v10i2.1458>.
- Putra, L.S.A., Gunawan, V.A. and Saragih, A.S. (2023) 'Detection of Actinic Keratosis Skin Cancer Using Gray Level Co-occurrence Matrix Texture Extraction and Color Extraction With Support Vector Machine Classification', *Teknik*, 44(2), pp. 158–166. Available at: <https://doi.org/10.14710/teknik.v44i2.44895>.
- Rahman, S. *et al.* (2024) 'Normalization Layer Enhancement in Convolutional Neural Network for Parking Space Classification', *MATRIK : Jurnal Manajemen, Teknik Informatika dan Rekayasa Komputer*, 23(3), pp. 557–568. Available at: <https://doi.org/10.30812/matrik.v23i3.3871>.
- Al Rivan, M.E. and Riyadi, A.G. (2021) 'Perbandingan Arsitektur LeNet dan AlexNet Pada Metode Convolutional Neural Network Untuk Pengenalan American Sign Language', *Jurnal Komputer Terapan*, 7(1), pp. 53–61. Available at: <https://doi.org/10.35143/jkt.v7i1.4489>.
- Schadendorf, D. *et al.* (2023) 'EJC Skin Cancer', *EJC Skin Cancer*, 1(April), p. 100001. Available at: <https://doi.org/10.1016/j.ejcskn.2023.100001>.
- Sitepu, A.C. and Sigiro, M. (2021) 'Analisis Fungsi Aktivasi ReLu Dan Sigmoid Menggunakan Optimizer SGD Dengan Representasi MSE Pada Model Backpropagation', *Jurnal Teknik Informatika Komputer Universal*, 1(1), pp. 12–25.
- Wibawa, L.P. *et al.* (2019) 'The epidemiology of skin cancer at Dr. Cipto Mangunkusumo National Central General Hospital from 2014 to 2017', *Journal of General-Procedural Dermatology & Venereology Indonesia*, 4(1), pp. 11–16. Available at: <https://doi.org/10.19100/jdvi.v4i1.162>.
- Wilvestra, S., Lestari, S. and Asri, E. (2018) 'Studi Retrospektif Kanker Kulit di Poliklinik Ilmu Kesehatan Kulit dan Kelamin RS Dr. M. Djamil Padang Periode Tahun 2015-2017', *Jurnal Kesehatan Andalas*, 7(Supplement 3), p. 47. Available at: <https://doi.org/10.25077/jka.v7i0.873>.
- Yahya, Y.F. *et al.* (2021) 'Pemberdayaan tenaga kesehatan pada fasilitas kesehatan primer di Kecamatan Sungsang: pengenalan kanker kulit', *Jurnal Pengabdian Masyarakat Humanity and Medicine*, 2(2), p. 9. Available at: <https://doi.org/10.32539/Hummed.V2I2.55>.
- Yohannes, R. and Al Rivan, M.E. (2022) 'Klasifikasi Jenis Kanker Kulit Menggunakan CNN-SVM', *Jurnal Algoritme*, 2(2), pp. 133–144. Available at: <https://doi.org/10.35957/algoritme.v2i2.2363>.
- Yuniarti, T. and Anggraeni, T. (2018) 'Dampak Tempat Pembuangan Akhir Sampah Putri Cempo Surakarta Terhadap Penyakit Kulit Pada Masyarakat Mojosongo', *Jurnal Ilmiah Rekam Medis dan Informatika Kesehatan, ISSN 2086-2628*, 8(1), pp. 26–29. Available at: <https://www.ejurnalinfokes.apikescm.ac.id/index.php/infokes/article/view/193/166>.
- Zafar, A. *et al.* (2022) 'A Comparison of Pooling Methods for Convolutional Neural Networks', *Applied Sciences (Switzerland)*, 12(17), pp. 1–21. Available at: <https://doi.org/10.3390/app12178643>.