

BAB II TINJAUAN PUSTAKA

2.1 Kanker Kulit

Kanker Kulit merupakan sel kanker yang menyerang organ tubuh kita yang paling luar yaitu kulit. Kulit tersusun dari miliaran sel. Dengan pola hidup yang tidak sehat, dan sering terpaparnya sinar ultraviolet , atau pun *toxin* dan faktor genetika tertentu, akan mengakibatkan sel-sel penyusun kulit mengalami pertumbuhan yang abnormal dan berkembang menjadi sel kanker [1].

Kanker kulit berdasarkan tingkat berbahayanya dibagi menjadi 2 jenis yaitu *Benign* dan *Malignant*. *Benign* adalah kanker kulit jinak atau biasa di sebut tumor , jarang mengancam nyawa, bisa di buang dan tidak akan kambuh kembali dan tidak menyebar kebagian tubuh lainnya (contoh tahi lalat) , sedangkan *Malignant* merupakan sel kanker ganas, bisa mematikan, jika dibuang bisa tumbuh kembali, dan dapat menyebar kebagian lainnya [7].

Contoh kasus kanker kulit *Malignant* yang paling umum diantaranya *Melanoma* yang menyerang melalui sel pigment kulit, *Basal cell carcinoma* yang menyerang sel kulit basal, biasanya karena sinar uv dan menyerang pada bagian wajah, lalu *squamous* yang menyerang dari sel kulit *squamous* sering menyerang orang berkulit gelap dan menyerang area yang tidak disinari matahari seperti kaki [7] .

2.2 Citra

Menurut [8] citra adalah representasi objek 2 dimensi dalam bentuk kumpulan titik-titik atau piksel-piksel yang berwarna.

2.2.1 Pengolahan Citra

Pengolahan citra digital adalah teknik pemrosesan citra foto maupun gambar bergerak untuk meningkatkan kualitas citra agar dapat dengan mudah dimengerti baik oleh manusia atau mesin komputer[8].

Pengolahan citra dapat didefinisikan sebagai kegiatan untuk memeriksa citra dengan tujuan mengidentifikasi objek dan menentukan signifikansinya. Pengolahan citra secara digital pada saat ini merupakan komponen yang sangat penting dalam berbagai aplikasi industri, komersil, dan juga merupakan komponen utama dalam bidang *computer vision*[9].

2.2.2 Jenis Citra

Menurut [10] ada 4 tipe citra digital yaitu:

- 1) *Binary Image*: merupakan tipe citra yang paling sederhana karena hanya memiliki 2 nilai yaitu hitam dan putih atau bernilai 0 dan 1. *Binary Image* juga disebut sebagai citra satu bit atau satu piksel karena hanya membutuhkan satu digit *binary* untuk merepresentasikan setiap piksel.
- 2) *Grayscale Image*: *binary image* merupakan citra yang *monochrome* atau hanya memiliki 1 warna karena hanya memiliki informasi tentang pencahayaan dan tidak memiliki informasi tentang warna. Biasanya citra ini mengandung 8 *bit* atau piksel yang memungkinkan citra untuk merepresentasikan 0-255 tingkat kecerahan(*gray*) citra.
- 3) *Indexed Image*: sebuah *indexed image* terdiri dari *array* dan matriks *colormap*. Nilai piksel di dalam *array* merupakan indeks langsung dari *colormap*. *Colormap* adalah matriks *m-by-3* yang berisi nilai *floating point*

(0 sampai 1). Setiap baris merepresentasikan komponen *RGB* dari satu warna.

- 4) *RGB Image*: citra *RGB* tidak menggunakan *color map*, citra direpresentasikan dengan 3 komponen warna yaitu *RGB*. Citra *RGB* menggunakan standar *monochrome 8 bit* dan mempunyai 24 piksel dimana setiap 8 pikselnya merepresentasikan masing-masing warna dari *RGB*.

2.3 Preprocessing

Preprocessing adalah proses meningkatkan informasi dari suatu citra dengan mengurangi distorsi yang tidak diinginkan atau memperkuat beberapa fitur citra untuk proses pengolahan proses pengolahan selanjutnya. Teknik preprocessing menggunakan berbagai teknik seperti penyesuaian ukuran dan bentuk citra secara dinamis, filtrasi noise, konversi citra, perbaikan citra, dan lainnya[11].

2.3.1 Median Filtered

Median Filtered adalah proses pengolahan citra untuk meningkatkan kualitas suatu citra dengan mengurangi *salt-and-pepper noise* di citra tersebut [12].

Prinsip dari filter median adalah menggantikan nilai *gray level* dari setiap piksel dengan nilai median *gray level* dari piksel-piksel sekitar piksel tersebut. Untuk *median filtering*, kita menentukan ukuran kernel, yaitu ukuran area yang akan diambil nilai mediannya, dan mencatat nilai piksel yang tercakup oleh kernel. Kemudian, kita menghitung median dari nilai-nilai tersebut. Jika kernel mencakup jumlah piksel genap, maka digunakan rata-rata dari dua nilai median. Sebelum memulai *median filtering*, kita perlu menambahkan angka nol di sekitar tepi baris dan tepi kolom gambar agar proses filtering berjalan dengan baik [13]

2.3.2 CLAHE

Contrast Limited Adaptive Histogram Equalization (CLAHE) adalah salah satu metode Histogram Equalization yang digunakan untuk meningkatkan kontras pada citra guna meningkatkan peluang deteksi kanker [14]. Histogram Equalization mengatur kontras dalam sebuah citra dengan memanipulasi histogramnya. Metode ini meningkatkan kontras global citra dengan meratakan distribusi intensitasnya secara keseluruhan. Hal ini memungkinkan area-area dengan kontras lokal yang rendah untuk mendapatkan kontras yang lebih tinggi. Histogram equalization mencapai hal ini dengan secara efektif menyebarkan nilai intensitas yang padat dalam histogram ke seluruh rentang histogram [15]. Histogram dari citra *greyscale* dihitung dengan cara berikut:

$$g(k) = (L - 1) * \sum n(j) / n$$

dimana

$k = 0, 1, 2, 3, \dots, L-1$

L = Nilai dari gray level di citra


$j = 0, 1, 2, \dots, k$

$n(j)$ = number of pixels of gray level j

n = total number of pixels

$n(j)/n$ = CDF for pixel value k

Contrast Limited Adaptive Histogram Equalization (CLAHE) dapat meningkatkan kontras yang baik dengan memberikan batasan atas pada nilai intensitas piksel untuk mencegah kontras yang berlebihan pada daerah yang seragam. *CLAHE* membatasi amplifikasi dengan memotong histogram pada nilai yang telah ditentukan sebelum menghitung *CDF (Cumulative Distribution Function)*. Nilai yang ditentukan ini disebut sebagai batasan pemotongan (*clip limit*). Bagian histogram di atas batasan pemotongan dipotong dan didistribusikan secara merata ke seluruh histogram [15].



Gambar 2.1. Clip Limit(CLAHE)

2.3.3 Segmentasi Citra

Segmentasi citra merupakan proses yang paling pertama dilakukan untuk dapat di analisis dan diproses oleh komputer dengan mengklasifikasikan *pixel* dari sebuah gambar. Segmentasi citra memiliki tujuan untuk membagi gambar menjadi beberapa bagian untuk mendapatkan wilayah pada gambar yang memiliki suatu kesamaan berdasarkan variabel yang ditentukan. Menurut [16] secara umum terdapat 4 buah kategori segmentasi citra yaitu:

- a. *Thresholding*: mensegmentasi citra dengan berdasarkan pada *gray level* atau seberapa intensitas nilai dari *pixel*. Tantangannya dalam metode ini adalah menentukan *gray level* yang sesuai untuk membagi setiap *pixel* menjadi 2 kategori yaitu gelap dan terang.
- b. *Edge detection*: membagi citra dengan mendeteksi tepi dari citra lalu mengelompokkannya ke beberapa bagian untuk merepresentasikan pembatas antar objek citra
- c. *Region extraction*: membagi seluruh citra menjadi beberapa bagian kecil berdasarkan kriteria yang telah ditentukan, biasanya menggunakan kesamaan dari intensitas, warna, dan tekstur sebagai kriteria.
- d. *Clustering*: mensegmentasi citra dengan mengklasifikasikan pola atau objek ke dalam beberapa *cluster* dengan karakteristik yang mirip.

2.3.4 Deteksi Tepi (*Harris corner detection*)

Harris Corner Detection adalah teknik *preprocessing* untuk mendapatkan garis tepi dari citra. Berdasarkan [5] Untuk mendeteksi tepian pada citra diperlukan perhitungan berdasarkan persamaan di bawah ini :

$$\begin{aligned} har &= \det[\mu(\sigma_I, \sigma_D)] - \alpha [\text{trace}(\mu(\sigma_I, \sigma_D))]^2 \\ &= g(I_x^2)g(I_y^2) - [g(I_x I_y)]^2 - \alpha [g(I_x^2) + g(I_y^2)]^2 \end{aligned}$$

Dimana :

$$\mu(\sigma_I, \sigma_D) = g(\sigma_I) * \begin{bmatrix} I_x^2(\sigma_D) & I_x I_y(\sigma_D) \\ I_x I_y(\sigma_D) & I_y^2(\sigma_D) \end{bmatrix}$$

Pada persamaan di atas, dilakukan turunan I_x dan I_y dari gambar I . I_x^2 dan I_y^2 merupakan hasil perkalian turunan I_x dan I_y , begitu pula dengan I_x dan I_y merupakan hasil perkalian turunan gambar I_x dan I_y . $g(\sigma_I)$ adalah filter Gaussian. Pada persamaan 1, jika nilai "har" lebih besar dari nol, itu dianggap sebagai sudut (*corner*), sedangkan jika nilainya kurang dari nol, itu dianggap sebagai tepi (*edge*) [5], [17].

2.3.5 Segmentasi Region Growing

Lebih lanjut [18] mengemukakan algoritme region growing dimulai dari segmentasi awal yang tidak lengkap dan mencoba untuk menggabungkan piksel yang tidak berlabel ke salah satu region Region awal biasanya disebut daerah benih atau seed. Keputusan apakah suatu piksel harus bergabung dengan suatu wilayah atau tidak didasarkan pada beberapa fungsi fitness yang mengungkapkan kesamaan antara wilayah dan calon piksel.


Seperti yang diusulkan dalam [19], urutan pemrosesan piksel ditentukan oleh antrian prioritas global yang mengurutkan semua kandidat piksel berdasarkan nilai fitness nya. Algoritma segmentasi gambar menetapkan piksel ke dalam region yang homogen, misalnya, dapat diklasifikasikan ke dalam kategori dengan akurasi lebih tinggi daripada yang dapat diperoleh dengan mengklasifikasikan piksel individu. Pertumbuhan region adalah kelas teknik yang digunakan dalam algoritma segmentasi citra di mana, biasanya dibangun oleh proses aglomerasi yang menggabungkan piksel ke wilayah ketika piksel tersebut berdekatan dengan region dan serupa dalam *property*.

2.3.6 Klasifikasi Citra Berbasis Deep Learning

RNN merupakan sebuah kelas dari jaringan saraf tiruan yang memiliki hubungan antara nodenya membentuk grafik berarah dengan urutan variabel. RNN memiliki variasi seperti GRU (Gated Recurrent Units) dan LSTM (Long Short-Term Memory Network) yang meningkatkan kinerja algoritme RNN. Struktur *RNN* terdiri dari *input layer*, satu atau lebih *hidden layer*, dan *output layer* [20].

Struktur *RNN* terdiri dari lapisan input, satu atau lebih lapisan tersembunyi, dan lapisan output. *RNN* memiliki struktur seperti rantai dengan modul yang berulang. Modul ini berfungsi sebagai memori untuk menyimpan informasi penting dari langkah-langkah sebelumnya. *RNN* juga menggunakan *feedback loop* yang memungkinkan jaringan saraf untuk menerima urutan input. Dengan demikian, *output* dari langkah sebelumnya akan diteruskan ke jaringan untuk mempengaruhi hasil langkah berikutnya.


Gambar 2.1 menggambarkan secara sederhana cara kerja algoritme RNN dengan satu unit input, satu unit *output*, dan unit tersembunyi yang berulang, yang berkembang menjadi jaringan yang lebih kompleks. X_t mewakili input dari langkah waktu t , dan h_t adalah output dari langkah waktu t [21].



Gambar 2.2: Gambaran Cara Kerja RNN

Beberapa penelitian sebelumnya telah berhasil mengimplementasikan *RNN* dalam bidang pengolahan citra, penggunaan *RNN* untuk deteksi penyakit pada kanker payudara [22], penggunaan *RNN-LSTM* untuk identifikasi penyakit kanker rahim[23] , dan penggunaan Dense *RNN* untuk segmentasi citra jantung [24].

Berdasarkan [24] cara kerja umum variasi metode *RNN*, seperti *LSTM*, dapat dilihat dalam Gambar 2.3. Setiap sel *LSTM* menerima informasi dari sel sebelumnya dan meneruskannya ke sel berikutnya.



Gambar 2.1: Gambaran Cara Kerja *LSTM*

Berdasarkan [25] dalam *LSTM*, terdapat komponen yang disebut *memory cell* dan *gate inputs*. Terdapat empat jenis *gate inputs* yang dikenal sebagai *forget gate*, *input gate*, *cell gate*, dan *output gate*. Fungsi aktivasi yang digunakan dalam gate-gate ini adalah sigmoid, yang menghasilkan nilai antara 0 dan 1. Pada *forget gate*, setiap data masukan diproses dan diputuskan apakah data tersebut akan dihapus atau disimpan dalam memori. Rumus yang digunakan untuk *forget gate* adalah sebagai berikut:

$$f_t = \sigma(W_f \cdot [h_{t-1}, x_t] + b_f)$$

Setelah *forget gate*, langkah selanjutnya adalah *input gate*, yang terdiri dari dua tahap. Tahap pertama adalah menentukan nilai mana yang akan diperbarui menggunakan fungsi aktivasi sigmoid. Tahap kedua melibatkan fungsi aktivasi tan h yang menghasilkan vektor nilai baru yang akan disimpan dalam *memory cell*. Berikut adalah rumus yang digunakan untuk *input gate*:

$$i_t = \sigma(W_i \cdot [h_{t-1}, x_t] + b_i)$$

$$\hat{c}_t = \tanh(W_c \cdot [h_{t-1}, x_t] + b_c)$$

Setelah tahap *input gate*, langkah berikutnya adalah *cell gate*. Pada tahap ini, nilai *memory cell* sebelumnya digantikan dengan nilai baru yang dihasilkan dari kombinasi nilai dari *forget gate* dan *input gate*. Berikut adalah rumus yang digunakan untuk *cell gate*:

$$c_t = f_t * c_{t-1} + i_t * \hat{c}_t$$

Pada tahap terakhir, yaitu *output gate*, dilakukan seleksi nilai dari *memory cell* yang akan dikeluarkan. Hal ini dilakukan dengan menggunakan fungsi

aktivasi sigmoid. Selanjutnya, nilai yang telah dipilih tersebut akan dimasukkan ke dalam *memory cell* dengan fungsi aktivasi tanh. Terakhir, kedua nilai ini akan dikalikan untuk menghasilkan nilai keluaran. Berikut adalah rumus yang digunakan untuk *output gate*:

$$o_t = \sigma(W_o \cdot [h_{t-1}, x_t] + b_o)$$

$$h_t = o_t \tanh(c_t)$$

2.4 Evaluasi Metode Segmentasi

Pengukuran kualitas algoritma segmentasi merupakan langkah penting dalam penelitian ini. Evaluasi algoritma segmentasi dilakukan menggunakan beberapa metrik yang telah ditentukan, yaitu *Precision* (P), *Recall* (R), dan *Accuracy* (ACC). Metrik-metrik ini dipilih karena memberikan wawasan yang relevan terhadap kemampuan algoritma dalam mengidentifikasi piksel-piksel *foreground* dengan akurat [26].

Dalam proses evaluasi, algoritma segmentasi akan dibandingkan dengan ground truth mask yang telah diketahui. Metrik *Precision* akan mengukur seberapa baik algoritma mampu mengidentifikasi piksel-piksel *foreground* secara benar, sedangkan metrik *Recall* akan menunjukkan kemampuan algoritma dalam mengenali piksel-piksel *foreground* yang sebenarnya. Selain itu, metrik *Accuracy* akan memberikan gambaran keseluruhan tentang kebenaran algoritma dalam memisahkan piksel-piksel *foreground* dan *background* secara keseluruhan.

Untuk menghitung *Accuracy*, *precision* dan *recall*, ditentukan dengan persamaan berikut :

$$\text{Precision} = \frac{TP}{TP+FP}$$
$$\text{Recall} = \frac{TP}{TP+FN}$$
$$\text{Accuracy} = \frac{TP + T}{TP+TN+FP+FN}$$

Dimana *TP* (*True Positive*) menunjukkan jumlah piksel foreground yang diidentifikasi dengan benar, sedangkan jumlah piksel *background* yang diakui dengan tepat sebagai latar belakang disebut sebagai *TN* (*True Negative*). Jumlah piksel *background* yang diberi label sebagai foreground disebut *FP* (*False Positive*) dan jumlah piksel *foreground* yang salah diidentifikasi sebagai *background* disebut *FN* (*False Negative*).

2.5 Evaluasi Metode Deep Learning

Berdasarkan Penelitian [27] kinerja model deep learning dapat dievaluasi menggunakan beberapa metrik, seperti akurasi, presisi, dan *recall*. Metrik-metrik ini memberikan penilaian tentang kemampuan model untuk melakukan klasifikasi dengan tepat berdasarkan data dan label yang sebenarnya.

Berikut adalah rumus-rumus untuk menghitung metrik-metrik evaluasi tersebut: Akurasi (*Accuracy* didefinisikan sebagai proporsi dari sampel yang telah dikenali dengan benar oleh model dibandingkan dengan total jumlah sampel).

$$Accuracy = (TP + TN) / (TP + FN + FP + TN) \times 100\%$$

Presisi didefinisikan sebagai proporsi dari jumlah sampel positif yang benar-benar dikenali sebagai positif oleh model dibandingkan dengan total jumlah sampel positif yang diprediksi.

$$Precision = TP / (TP + FP) \times 100\%$$

Recall didefinisikan sebagai proporsi dari jumlah sampel positif yang benar-benar dikenali sebagai positif oleh model dibandingkan dengan total jumlah sampel positif yang sebenarnya.

$$Recall = TP / (TP + FN) \times 100\%$$

Dalam konteks model deep learning, nilai TP (True Positive), TN (True Negative), FP (False Positive), dan FN (False Negative) berperan penting dalam perhitungan metrik-metrik evaluasi ini. TP adalah jumlah dari sampel positif yang telah dengan benar diprediksi sebagai positif oleh model. TN adalah jumlah dari sampel negatif yang telah dengan benar diprediksi sebagai negatif oleh model. FP adalah jumlah dari sampel negatif yang salah diprediksi sebagai positif oleh model, dan FN adalah jumlah dari sampel positif yang salah diprediksi sebagai negatif oleh model.

Hasil evaluasi ini akan memberikan penilaian tentang kemampuan model deep learning semakin tinggi nilai akurasi, presisi, dan recall, semakin baik kinerja model dalam melakukan tugas klasifikasi dengan akurat dan dapat diandalkan.

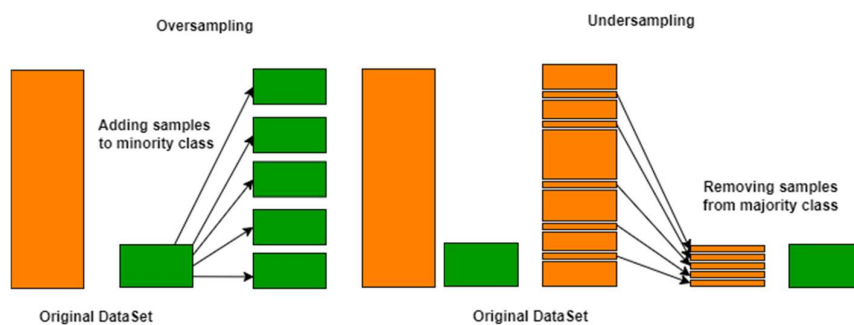
2.6 Imbalanced Dataset

Banyak penelitian menggunakan dataset publik yang sering kali memiliki ketidakseimbangan dalam jumlah data di setiap direktori atau kelas. Hal ini dapat menyebabkan masalah dalam klasifikasi, karena kelas dengan lebih banyak data akan muncul lebih sering saat dilakukan prediksi dibandingkan dengan kelas yang memiliki jumlah data yang lebih sedikit. Menurut [28], terdapat dua cara untuk menangani masalah dataset yang tidak seimbang, yaitu oversampling dan undersampling.

Oversampling adalah teknik yang melibatkan penambahan atau duplikasi sampel pada kelas yang memiliki jumlah data yang lebih sedikit daripada kelas dengan jumlah data terbanyak. Tujuannya adalah agar kelas yang awalnya memiliki jumlah data yang lebih sedikit dapat memiliki jumlah data yang setara dengan kelas yang memiliki jumlah data terbanyak.

Di sisi lain, undersampling adalah teknik yang melibatkan penghapusan data dari kelas yang memiliki jumlah data paling banyak sehingga jumlah data pada kelas tersebut menjadi seimbang dengan kelas yang memiliki jumlah data paling sedikit.

Perbedaan antara oversampling dan undersampling dapat dilihat dalam Gambar 2.4 dan Gambar 2.5.



Gambar 2.4: Gambaran Cara Kerja *Oversampling* dan *Undersampling*

2.7 Penelitian Terkait

Pada sub-bab ini akan dibahas tentang penelitian-penelitian yang telah dilakukan sebelumnya untuk menjelaskan tentang *research gap* yang ada pada penelitian sebelumnya.

Penelitian [5] menggunakan metode *Region Growing* untuk mendeteksi penyakit jejas. Pada penelitian ini peneliti menggunakan 3 metode untuk preprocessing data sebelum di lakukan segmentasi dengan *region growing*. Dari hasil penelitian ini didapatkan metode preprocessing grayscale image digabungkan dengan *region Growing* mendapatkan tingkat akurasi yang cukup tinggi untuk deteksi jejas kulit yaitu sebesar 95%. Saran dari peneliti untuk menggunakan teknik yang sama untuk diterapkan pada penyakit kulit yang lainnya. Hal yang bisa di implementasikan dari penelitian [5] adalah penentuan seed berdasarkan algoritma *Harris Corner Detection* , seed diambil berdasarkan tepian dengan nilai intensity tertinggi akan digunakan sebagai *initial seed* untuk proses segmentasi dengan *region growing* .

Penelitian [29] untuk melakukan segmentasi pada jejas kanker kulit menggunakan metode *grabcut* yang dipadukan dengan preprocessing *Corner borders removal* ,*Hairs removal* dan *Image enhancement* mendapatkan akurasi sebesar 77% pada dataset ph2. saran peneliti untuk mencoba metode lain dikarenakan metode GrabCut menghasilkan banyak over segmentasi pada citra yang disegmentasi.

Pada penelitian [6] untuk mendeteksi kanker kulit peneliti menggunakan metode RNN untuk klasifikasi dan dan *K-mean clustering* untuk segmentasi , dalam penelitian ini didapatkan tingkat akurasi yang tinggi 93 %. Teknik *preprocessing* yang digunakan pada penelitian ini adalah median filter, proses ini dilakukan sebelum proses klustering data dengan *K-mean clustering*. Hal yang disayangkan dari penelitian ini adalah dataset yang digunakan hanya memiliki 83 citra.

Pada penelitian [23] untuk mendeteksi kanker rahim berdasarkan citra Kolposkopi (kondisi leher rahim) metode RNN-LSTM digunakan untuk klasifikasi. Sebelum dilakukan data train, citra gambar perlu di preprocessing dengan *Histogram Equalization* dan median filter untuk peningkatan kualitas citra yang lebih baik. Dari hasil penelitian ini didapatkan akurasi sebesar 66% . Dikarenakan akurasi yang kurang besar peneliti menyarankan menggunakan metode lain baik untuk klasifikasi dan *preprocessing* data.

Penerapan preprocessing citra yang tepat bisa berpengaruh ke hasil akurasi deteksi kanker kulit. Hal ini di tunjukan pada penelitian [30], teknik preprocessing *CLAHE* dilakukan sebelum proses train data dan didapatkan nilai akurasi 87.99%. penerapan *CLAHE* dapat meningkatkan kontras pada gambar sehingga akurasi yang didapatkan dengan metode *CNN* untuk klasifikasi jenis kanker dinilai baik. Pada penelitian ini dilakukan undersampling data untuk menyeimbangkan data dari setiap kelas di dataset. Hal ini baik dilakukan agar bobot dari setiap kelas sama saat di tahap *training*.

Teknik preprocessing citra *CLAHE* dan *MSRCR (Multiscale Retinex with Color Restoration)* digunakan bersamaan dengan *VGG-16* untuk prediksi kanker kulit di penelitian [15]. Penelitian tersebut mendapatkan tingkat akurasi yang cukup tinggi sebesar 92.6% di metode *CLAHE + VGG-16* dan 91.9% pada *MSRCR + VGG-16*.

Berikut ini adalah rangkuman dari penelitian terkait dalam bentuk tabel yang disajikan pada tabel di bawah ini.

Tabel 2.1 Rangkuman Penelitian Terkait

No	Peneliti	Judul Penelitian	Tahun	Metode dan Hasil Penelitian	Kelebihan	Kelemahan
1	Imtiaz, Izbaila Ahmed, Imran Ahmad, Misbah [5]	Segmentation of Skin Lesion Using Harris Corner Detection and Region Growing	2019	Region Growing, Harris Corner Detection based akurasi segmentasi 95%	Akurasi segmentasi tinggi	Penelitian sebatas segmentasi citra
2	Gowthami V, Sneha G [6]	Melanoma Detection Using Recurrent Neural Network	2021	Median filter, K-mean , RNN Akurasi klasifikasi 93%	Berhasil mendeteksi Kanker kulit dengan Akurasi klasifikasi 93%	Kelas yang digunakan sedikit hanya 2 , dataset training sangat sedikit

Tabel 2.2 Lanjutan rangkuman penelitian terkait

3	H. Asyhar, A. Z. Foady, M. Thohir, A. Z. Arifin, D. Z. Haq [23]	Implementation LSTM Algorithm for Cervical Cancer using Colposcopy Data	2020	Histogram Equalization, median filter, RNN-LSTM Akurasi klasifikasi 66%	Penerapan Histogram Equalization, dan median filter Untuk peningkatan kualitas citra	Akurasi kurang baik
4.	A. Jain, N. Mittal, and S. Nain . [30]	CNN-based Recognition of Skin Cancer Using Contrast Limited Adaptive Histogram Equalization	2021	CLAHE , CNN, Under sampling Akurasi klasifikasi 87%	Akurasi klasifikasi Cukup baik	-
5.	Mihir Mehta, Kaushik Metha [15]	Study of Effects of Image Enhancement Techniques on Early Detection of Skin Cancer	2021	VGG-16 CLAHE MSRCR Akurasi klasifikasi 92.6%	Akurasi klasifikasi Cukup baik	Hanya menggunakan 2 kelas