

# **Sistem Pengenalan Jenis Kanker *Melanoma* pada Citra Menggunakan *Gray Level Co-occurrence Matrices (GLCM)* dan *K-Nearest Neighbor (KNN) Classifier***

**YOULLIA INDRAWATY NURHASANAH, IRMA AMELIA DEWI,  
FEVLY PALLAR**

Program Studi Informatika, Institut Teknologi Nasional Bandung  
Email: [youllia@itenas.ac.id](mailto:youllia@itenas.ac.id)

*Received* 31 Maret 2020 | *Revised* 30 April 2020 | *Accepted* 30 Mei 2020

## **ABSTRAK**

*Melanoma dikategorikan sebagai bentuk kanker kulit yang paling berbahaya menurut [skincancer.org](http://skincancer.org). Kanker kulit ini bertumbuh dan berkembang oleh kerusakan DNA pada sel-sel kulit yang umumnya disebabkan oleh radiasi ultraviolet dari matahari. Pada penelitian ini dibuatkan suatu sistem yang dapat membantu pihak medis untuk memprediksi suatu tipe atau jenis dari suatu kanker melanoma dengan proses antara lain, optimalisasi postprocessing melalui morphological closing, pembentukan matriks-matriks gray level co-occurrence (GLCM) untuk pengestraksian fitur-fitur tekstur statistika dan K-Nearest Neighbor (KNN) sebagai metode klasifikasinya. Hasil dari pengujian menunjukkan bahwa ekstraksi ciri tekstur statistika bermanfaat dalam pengenalan kanker ini dimana diperoleh hasil akurasi mencapai 93.33% oleh classifier pada kategori pengujian positif melanoma dan 86.66 % pada kategori kelas melanoma.*

**Kata kunci:** *Melanoma, GLCM, K-Nearest Neighbor, Otsu Thresholding*

## **ABSTRACT**

*Melanoma is categorized as the most dangerous form of skin cancer, according to [skincancer.org](http://skincancer.org). This skin cancer grows and develops due to DNA damage to skin cells which is generally caused by ultraviolet radiation. In this study, a system was created to help medical parties predict a type or type of melanoma cancer. This system was performed with morphological closing processes, the formation of gray level co-occurrence (GLCM) matrices for extraction of features of statistical textures, and K-Nearest Neighbor (KNN) as a classification method. The test results showed that the system recognized this cancer with an accuracy of 93.33% for the positive image of melanoma and 86.66% for the melanoma class category.*

**Keywords:** *Melanoma, GLCM, K-Nearest Neighbor, Otsu Thresholding*

## 1. PENDAHULUAN

*Melanoma* dikategorikan sebagai bentuk kanker kulit yang paling berbahaya (**Sheha, Mabrouk, & Sharawy, 2012**). Kanker kulit ini bertumbuh dan berkembang oleh kerusakan DNA pada sel-sel kulit yang umumnya disebabkan oleh radiasi *ultraviolet* dari matahari (**Damayana, Atmaja, & Fauzi, 2016**). Resiko kanker melanoma meningkat pada orang-orang dibawah usia 40, khususnya wanita. Pendeteksian kanker *melanoma* sedini mungkin dapat membantu pengobatan yang sesuai untuk mencegah kanker berkembang dan menyebar ke tahap yang lebih serius.

Perkembangan ilmu *image processing* dapat memfasilitasi prediksi terhadap jenis kanker ini dan penyakit kulit pada umumnya dengan relatif cepat. Pengidentifikasian jenis atau kelas suatu penyakit kulit yang terkandung pada sebuah citra *digital* adalah tugas yang cukup menantang (**Ansari & Sarode, 2017**). Pada umumnya, penyakit kulit tidaklah menunjukkan struktur geometris yang konstan, bervariasi pada kontras beserta karakteristik warnanya. Selain itu, penyakit yang terdapat pada kulit sebagian besar memiliki transisi yang lemah antara porsi penyakit dengan porsi kulit sehat di sekitarnya. Berdasarkan hal tersebut, proses pemisahan penyakit itu sendiri terhadap kulit secara sempurna pada tahapan segmentasi bukanlah hal yang mudah (**Gurkirat Kaur, 2015**).

Beberapa metode telah dikembangkan untuk menghasilkan klasifikasi citra yang optimal. Dalam penelitian kali ini penulis akan mengimplementasikan salah satu dari metode tersebut dengan berfokus pada karakteristik tekstur suatu citra yang dijabarkan melalui suatu fitur-fitur yang diperoleh melalui distribusi nilai-nilai intensitas abu pada suatu citra *grayscale* (**Albregtsen, 2018**) (**Sebastian, Unnikrishnan, & Balakrishnan, 2012**) (**Almomani, Alweshah, Alkhalaileh, Refai, & Qashi, 2019**). Fitur-fitur tersebut dikomputasi melalui matriks-matriks yang digenerasi dari beberapa orientasi yang disebut *Gray Level Co-occurrence Matrices (GLCM)* untuk kemudian diklasifikasikan menggunakan KNN (**Sheha, Mabrouk, & Sharawy, 2012**) (**Gurkirat Kaur, 2015**) (**Ansari & Sarode, 2017**) (**Damayana, Atmaja, & Fauzi, 2016**) *Nearest Neighbor (KNN)* untuk menentukan kelas suatu citra.

Untuk mengetahui efektifitas dan peranan metode GLCM serta K-Nearest Neighbor (KNN) classifier dalam pengidentifikasian melanoma pada sebuah citra melalui pengklasifikasian, maka dirumuskan beberapa hal, yaitu bagaimana sistem dapat mengidentifikasi serta menentukan jenis dari kanker melanoma pada citra yang diuji yaitu terdiri dari lima kelas atau tipe melanoma yang digunakan pada penelitian ini, yaitu *superficial spreading melanoma, nodular melanoma, lentigo maligna melanoma, acral lentiginous melanoma, dan amelanotic melanoma*. Selain itu, terdapat satu kelas ekstra yang kategorikan sebagai kelas non melanoma yang terdiri dari lima penyakit kulit umum non melanoma, yaitu eksim (dermatitis), impetigo, panu (*tinea versicolor*), cacar air (*varicella*), dan lupus. Sistem yang dikembangkan juga dapat mengukur seberapa efektif GLCM dan KNN (**Cheng, Zhang, Deng, Zhu, & Zong, 2014**) (**Zhang, Li, Zong, Zhu, & Cheng, 2017**) dalam pengenalan melanoma pada citra serta tipe dari melanoma tersebut, serta bagaimana sistem dapat mencapai performa classifier yang optimal. Tujuan dari penelitian ini sesuai dengan rumusan masalah yang telah ditentukan di atas, yaitu untuk membangun aplikasi dari sistem pengenalan jenis kanker kulit melanoma pada citra yang dapat mengenali kanker melanoma beserta jenisnya dengan performa classifier yang dijabarkan dengan nilai *accuracy* (akurasi) secara optimal dan aplikasi atau hasil penelitian ini ditujukan untuk masyarakat umum agar dapat mengenali jenis kanker kulit melanoma.

## 2. METODE PENELITIAN

### 2.1. Analisis Perencanaan Sistem

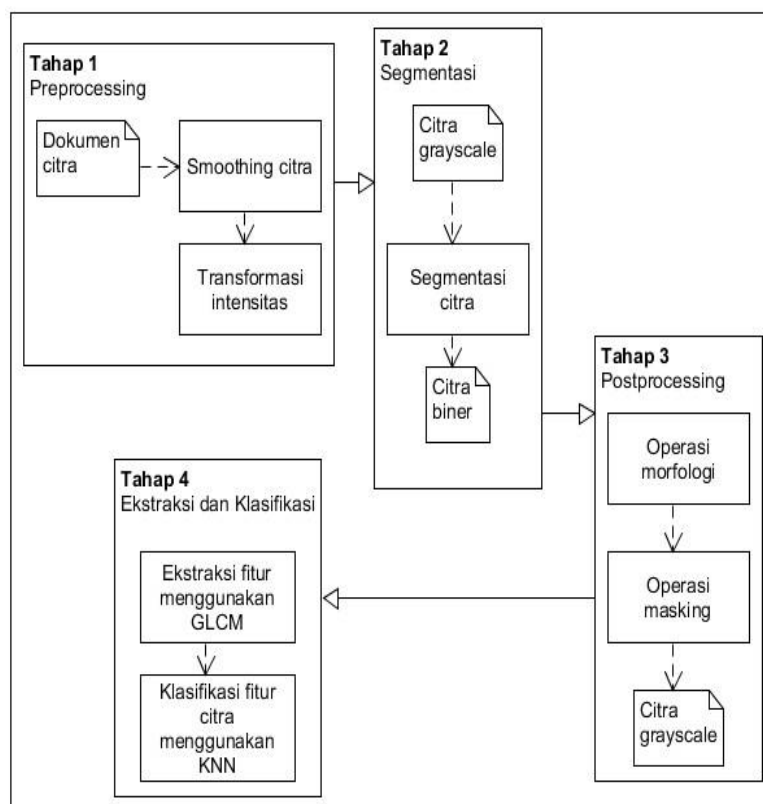
Tahap-tahap perencanaan pengembangan aplikasi sistem pengenalan jenis kanker *melonama* dapat dilihat pada Tabel 1 berikut.

**Tabel 1 Analisis Perencanaan Sistem**

No	Tahap	Keterangan
1.	Pengumpulan kebutuhan	Melakukan pengumpulan hal-hal yang dibutuhkan dalam sistem
2.	Perancangan cepat	Membuat perancangan sistem identifikasi jenis kanker <i>Melanoma</i>
3.	Membangun <i>prototyping</i>	Membuat <i>prototype</i> sistem identifikasi jenis kanker <i>Melanoma</i>
4.	Evaluasi <i>prototyping</i>	Melakukan evaluasi pada <i>prototype</i> yang sudah dibuat
5.	Mengkodekan sistem	<i>Prototype</i> yang sudah disepakati diterjemahkan ke dalam bahasa pemrograman <i>Matlab 2016a</i>

### 2.2. Tahapan Implementasi Sistem

Tahapan implementasi sistem pada penelitian ini dibagi ke dalam empat tahapan besar seperti yang ditunjukkan pada Gambar 1 berikut.



**Gambar 1. Tahapan Implementasi Sistem**

Tahap satu, yaitu *preprocessing* akan berfokus pada upaya optimalisasi pada citra abu (*grayscale*) sebelum citra itu diproses ke dalam tahapan segmentasi. Tahap dua, yaitu segmentasi akan berfokus pada pemecahan daerah citra melalui segmentasi untuk mempartisi porsi penyakit terhadap porsi *background*. Tahap tiga, yaitu *postprocessing* akan berfokus pada optimalisasi setelah tahap dua atau segmentasi dilakukan, termasuk proses *masking* pada citra biner terhadap citra *grayscale* dan tahap empat yaitu tahap ekstraksi fitur serta klasifikasi akan berfokus pada pembentukan matriks-matriks *gray level co-occurrence* dan pengekstraksian nilai-nilai fitur yang dikomputasi melalui masing-masing matriks *gray level co-occurrence* yang diperoleh dari beberapa orientasi lalu diakhiri pada tahapan klasifikasi untuk melakukan proses identifikasi maupun klasifikasi pada suatu citra yang diuji.

### 2.3. Flowchart Alur Komputasi Sistem

Seluruh citra uji dan citra latih akan melewati alur prosedur komputasi yang sama, yang terkandung pada tahapan *preprocessing*, segmentasi, *postprocessing*, ekstraksi fitur dan klasifikasi. Diagram alir (*flowchart*) dari alur komputasi sistem ditunjukkan pada Gambar 2.

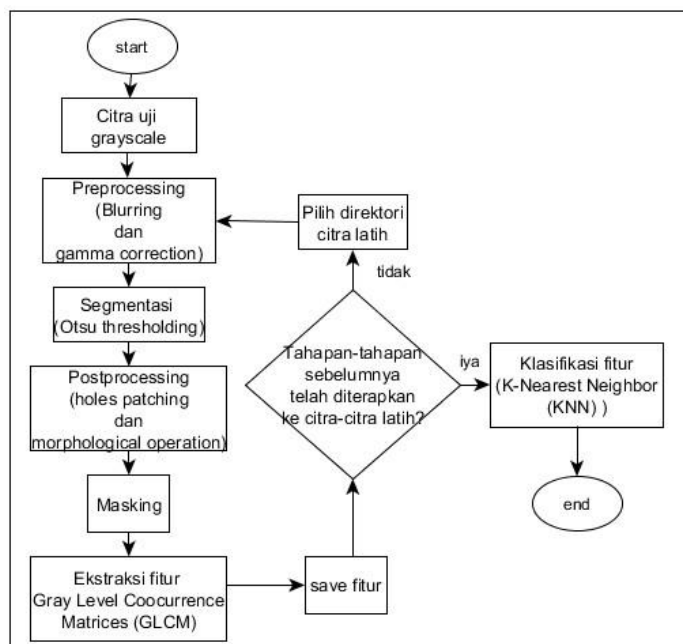
#### 2.3.1. Tahap *Preprocessing*

Tahap satu, yaitu *preprocessing* berfokus pada upaya optimalisasi pada citra abu (*grayscale*) sebelum citra itu diproses ke dalam tahapan segmentasi. Tahap ini terdiri atas proses *blurring* citra dan transformasi nilai intensitas.

#### 2.3.2. *Blurring* Citra

Operator atau filter konvolusi yang dipilih pada proses pengaburan citra adalah operator *Gaussian* untuk fungsi 2D dimana nilai standar deviasi ( $\sigma$ ) yang ditentukan secara manual, mengendalikan tingkat pengaburan suatu citra yang berdampak pada minimalisasi *noise*. Bobot-bobot pada *filter* ini digenerasi dengan Persamaan (1), dimana  $(x, y)$  adalah lokasi  $x$  dan  $y$  pada *mask*,  $\sigma$  adalah standar deviasi dan  $G(x, y)$  adalah bobot-bobot baru yang diperoleh. Derajat atau tingkat pengaburan citra di kendalikan oleh *standar deviasi* ( $\sigma$ ), semakin besar nilainya, semakin kabur (*blur*) citra yang diperoleh (Munir, 2004) (Mesquita, Corona, Souza, & Nobre, 2019).

$$G(x, y) = \frac{1}{(2\pi\sigma^2)} e^{\frac{-x^2+y^2}{2\sigma^2}} \quad (1)$$



Gambar 2. Flowchart Alur Prosedur Komputasi Sistem



Gambar 3. Amelanotic Melanoma (Sumber: Cancerwall.Com)



Gambar 4. Pengaburan pada Citra Amelanotic Melanoma dengan  $\sigma=2$

### 2.3.3. Transformasi Nilai Intensitas Citra (Gamma Correction)

Transformasi intensitas yang dilakukan pada penelitian ini adalah tipe transformasi yang bertujuan untuk menaikkan tingkat kecerahan (*brightness*) melalui koreksi *gamma* pada gambar agar *detail* dari porsi objek pada gambar dapat ditentukan dengan optimal. Kurangnya kecerahan pada citra dapat menyebabkan hasil segmentasi tidak menjadi optimal. Pada koreksi *gamma*, setiap nilai intensitas abu pada piksel ditransformasi secara non linier (Rahman, Rahman, Al-Wadud, Al-Quaderi, & Shoyaib, 2016) menggunakan Persamaan (2), dimana  $(x, y)$  adalah Lokasi  $(x, y)$  nilai intensitas dan  $A$  adalah nilai intensitas  $A$ . Sebelum mengaplikasikan *gamma correction*, asumsikan untuk citra dengan kedalaman 8-bit, terlebih dahulu dilakukan normalisasi pada nilai-nilai intensitas ke rentang  $[0, 1]$ , transformasi nilai-nilai tersebut, kemudian diskalakan lagi ke rentang  $[0, 2^8 - 1]$ .

$$t_{gamma}(x) = A \cdot x^\gamma, x \in [0,1] \quad (2)$$



Gambar 5. Lentigo Melanoma (Sumber: bccancer.bc.ca )




Gambar 6. Hasil Gamma Correction pada Citra Lentigo Melanoma dengan  $\gamma = 0.8$

Peningkatan kecerahan yang diperoleh bermanfaat pada tahapan segmentasi, khususnya jika terdapat transisi yang lemah antara porsi daerah-daerah penyakit dan kulit sehat disekitarnya.


## 2.4. Tahap Segmentasi

Penelitian ini menggunakan metode *Otsu automatic thresholding* untuk memutuskan nilai *thresholding* (nilai ambang) yang dipilih menjadi suatu ukuran nilai pemisahan antara daerah penyakit dan daerah kulit (*background*) pada citra. Proses *thresholding* menghasilkan citra biner dengan mengubah seluruh nilai piksel dibawah level nilai *threshold* ( $T$ ) ke 0 atau hitam dan seluruh piksel diatas level *threshold* ( $T$ ) ke 1 atau putih. Jika  $g(x,y)$  adalah citra biner hasil *thresholding* pada citra  $f(x,y)$  untuk nilai *threshold* ( $T$ ) tertentu (Gonzalez, Woods, & Eddins, 2009) maka dapat menggunakan Persamaan (3), dimana  $g(x,y)$  = Nilai intensitas citra biner pada lokasi  $(x,y)$  dan  $T$  = Nilai *threshold*. Umumnya, nilai 1 merepresentasikan objek pada citra dan 0 merepresentasikan *background*.

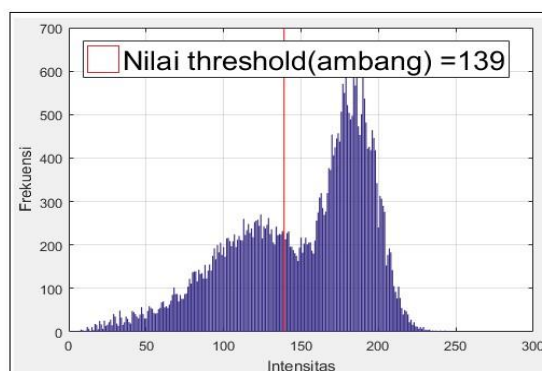
$$g(x,y) = \begin{cases} 1, & \text{if } f(x,y) \geq T \\ 0, & \text{if } f(x,y) < T \end{cases} \quad (3)$$



**Gambar 7. Superficial Spreading Melanoma Grayscale (Sumber: dermnetnz.org)**



**Gambar 8. Superficial Spreading Melanoma Hasil Segmentasi**



**Gambar 9. Pengambilan Nilai Ambang Melalui Metode Otsu Thresholding**

## 2.5. Tahap *PostProcessing*

Tahap tiga, yaitu *postprocessing* berfokus pada optimalisasi setelah tahap dua atau segmentasi dilakukan yang terdiri atas proses *morphological operations* dan proses *masking* pada citra biner terhadap citra *grayscale*.

### 2.5.1 *Morphological Operations*


Operasi ini akan digunakan untuk mengoptimalkan citra biner hasil segmentasi dari segi bentuk geometris citra, seperti penambalan daerah-daerah berlubang pada citra dan optimalisasi pada daerah-daerah perbatasan citra. Operasi yang digunakan adalah *closing* yang merupakan perpaduan *dilation* dan *erosion*. Operasi ini dapat dijabarkan sebagai berikut. Andaikan  $A$  ada set dari piksel-piksel dan  $B$  adalah *structuring element*  $s$ . Andaikan  $\bar{B}_s$

adalah refleksi B dari titik asalnya dan tergeser (*shifted*) sejauh s, maka proses dilasi ditulis dengan  $A \oplus B$ , *erosion* sebagai  $A \ominus B$ , dan *closing* sebagai  $A \bullet B$  jika set dari seluruh pergeseran memenuhi Persamaan (4)-(6) (Solomon & Breckon, 2011).


$$A \oplus B = \{s | (\bar{B}_s \cap A) \subseteq A\} \tag{4}$$

$$A \ominus B = \{s | Bs \subseteq A\} \tag{5}$$

$$A \bullet B = (A \oplus B) \ominus B \tag{6}$$



Gambar 10. Superficial Spreading Melanoma (sumber: dermnetnz.org)



Gambar 11. Hasil Segmentasi Menggunakan Otsu Thresholding




Gambar 12. Hasil Optimalisasi Citra Biner Menggunakan Morphological Closing

## 2.6. Tahap Ekstraksi Fitur Dan Klasifikasi

Tahap tiga, yaitu tahap *postprocessing* berfokus pada proses ekstraksi fitur-fitur *GLCM* dan klasifikasi.

### 2.6.1. GLCM

Fitur-fitur *GLCM* yang dikomputasi adalah nilai-nilai fitur dari matriks *gray level co-occurrence* yang digenerasi dari beberapa orientasi pengamatan pada jarak satu piksel seperti yang ditunjukkan pada Gambar 13 berikut.



Gambar 13. Relasi Pixel Matriks Gray Level Cooccurrence Pada Matriks Grayscale Yang Dari Sudut 0°, 45°, 90°, 135°

Dalam penelitian ini digunakan 32 level kuantisasi abu dan relasi simetris untuk menggenerasi matriks-matriks frekuensi pasangan nilai abu yang dibentuk dari masing-masing orientasi 0°, 45°, 90°, dan 135° pada jarak 1 piksel. Matriks-matriks ini akan memberikan informasi karakteristik tekstur statistika yang dideskripsikan sebagai fitur-fitur *GLCM* (Widodo, Widodo, & Supriyanto, 2018) (Barmawi, Zulkarnain, & Hidayat, 2017) (Shidnal, 2014) yang ditunjukkan pada Tabel 2 berikut:

**Tabel 2. Karakteristik atau fitur *GLCM***

FITUR – FITUR <i>GLCM</i>	
$Contrast = \sum_{i,j=1}^N P(i,j)(i-j)^2$	$Entropy = \sum_{i,j=1}^N P(i,j) \log P(i,j)$
$Correlation = \frac{\sum_{i,j=1}^N ((i-x)(j-y)P(i,j) - (\mu_x\mu_y))}{\sigma_x\sigma_y}$	$Autocorrelation = \frac{\sum_{i,j=1}^N (P_x - (\mu_x))(P_y - (\mu_y))}{\sigma_x\sigma_y}$
$Homogeneity = (P(i,j))^2$	$Sum\ of\ Square\ (variance) = \sum_{i,j=1}^N P(1 - \mu_x)^2 P(i,j)$
$Energy = \sqrt{\sum_{i,j=1}^N P(i,j)^2}$	$Sum\ of\ Average = \sum_{i,j=1}^N i P_{x+y}(i)$

Dimana  $P(i,j)$  adalah masing-masing nilai elemen pada matriks *gray level co-occurrence* dalam representasi peluang.  $i$  dan  $j$  adalah lokasi masing nilai tersebut.  $\mu$  adalah nilai *mean* (*mean* menurut interpretasi pada *GLCM*), dan  $\sigma$  adalah standar deviasi (**Albregtsen, 2018**) (**Widodo, Widodo, & Supriyanto, 2018**) (**Barmawi, Zulkarnain, & Hidayat, 2017**) (**Shidnal, 2014**). *Contrast* sebagai ukuran variasi intensitas lokal, *correlation* sebagai ukuran *linear dependence* dari level abu antara piksel-piksel pada posisi tertentu relatif ke posisi-posisi lainnya, *homogeneity* sebagai ukuran homogenitas suatu citra, *energy* yang menyatakan *joint probability occurrence* pada pasangan-pasangan piksel tertentu, *entropy* yang menyatakan ukuran keacakan distribusi tingkat keabuan, *Sum of Square* yang menyatakan selisih kuadrat dari nilai *mean*, *autocorrelation*, dan *sum average* (**Albregtsen, 2018**) (**Widodo, Widodo, & Supriyanto, 2018**) (**Barmawi, Zulkarnain, & Hidayat, 2017**) (**Shidnal, 2014**). Masing-masing nilai-nilai fitur *GLCM* yang digunakan sebagai input bagi *classifier* adalah nilai rata-rata fitur dari keempat orientasi tersebut. Jika  $F_i$  kita andaikan nilai rata-rata masing-masing fitur *ke-i* dari sudut  $0^\circ$ ,  $45^\circ$ ,  $90^\circ$ , dan  $135^\circ$  maka,

$$F_i = \frac{(F_i 0^\circ + F_i 45^\circ + F_i 90^\circ + F_i 135^\circ)}{4} \quad (7)$$

### 2.6.2. *K-Nearest Neighbor (KNN)*

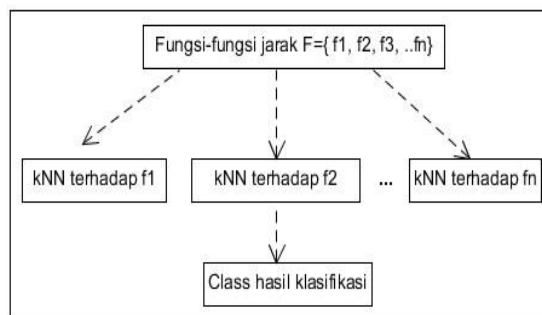
Varian *KNN* yang digunakan pada penelitian ini adalah *multiple different distance functions (DKNN)* (Wu, Cai, & Gao, 2010) yang skemanya ditunjukkan pada Gambar 15. DKNN akan mengumpulkan seluruh nilai ketetanggaan ( $K$ ) terdekat dari  $f^n$  dan kemudian melakukan *voting* untuk memutuskan kelas yang diuji, dimana,  $f^1, f^2, \dots, f^n$  dideskripsikan sebagai fungsi *Euclidean distance*.

$$f_n(x,y) = \sqrt{\sum_{i=1}^{n-1} (x_i - y_i)^2} \quad (8)$$



	Kelas	Contrast	Correlation	Homogeneity	Energy/U...	Entropy	Sum SQ...	Autocorre...	Sum Average
1	Acrolentigi...	0.0161	0.0021	0.0015	2.3269e-05	0.0130	0.4131	0.4051	0.0649
2	Acrolentigi...	0.0164	0.0016	0.0015	3.6022e-05	0.0123	0.2406	0.2324	0.0497
3	Acrolentigi...	0.0271	0.0013	0.0013	2.4506e-05	0.0130	0.2173	0.2039	0.0463
4	Acrolentigi...	0.0022	0.0022	0.0021	2.3438e-04	0.0078	0.0321	0.0311	0.0172
5	Acrolentigi...	0.0202	0.0021	0.0014	1.7440e-05	0.0133	0.2584	0.2484	0.0492
6	Amelanotic...	0.0091	0.0023	0.0019	8.4028e-05	0.0112	0.1854	0.1809	0.0423
7	Amelanotic...	0.0290	0.0015	0.0015	3.3823e-05	0.0128	0.5380	0.5235	0.0751
8	Amelanotic...	0.0082	0.0019	0.0020	1.1200e-04	0.0098	0.2944	0.2903	0.0560
9	Amelanotic...	0.0096	0.0017	0.0020	1.6504e-04	0.0093	0.6087	0.6040	0.0815
10	Amelanotic...	0.0214	0.0020	0.0015	2.4158e-05	0.0134	0.5284	0.5178	0.0738
11	Lentigo Ma...	0.0199	0.0020	0.0014	1.3763e-05	0.0135	0.2799	0.2700	0.0521
12	Lentigo Ma...	0.0226	0.0018	0.0015	3.0164e-05	0.0127	0.7336	0.7224	0.0884
13	Lentigo Ma...	0.0121	0.0016	0.0018	1.0467e-04	0.0103	0.5928	0.5868	0.0803
14	Lentigo Ma...	0.0102	0.0022	0.0017	4.7040e-05	0.0117	0.3817	0.3767	0.0632
15	Lentigo Ma...	0.0110	0.0017	0.0016	6.7342e-05	0.0112	0.2491	0.2437	0.0512
16	Nodular Me...	0.0312	0.0020	0.0013	1.3517e-05	0.0141	0.2548	0.2392	0.0472
17	Nodular Me...	0.0181	0.0022	0.0016	3.5440e-05	0.0130	0.3169	0.3079	0.0548
18	Nodular Me...	0.0418	0.0023	0.0014	2.3009e-05	0.0145	0.9372	0.9164	0.0958
19	Nodular Me...	0.0076	0.0022	0.0019	9.1065e-05	0.0104	0.2473	0.2436	0.0505
20	Nodular Me...	0.0149	0.0018	0.0016	4.6285e-05	0.0119	0.2039	0.1965	0.0451
21	Superficial ...	0.0064	0.0018	0.0017	1.0663e-04	0.0099	0.0718	0.0686	0.0264
22	Superficial ...	0.0176	0.0015	0.0016	5.9159e-05	0.0114	0.6104	0.6017	0.0812
23	Superficial ...	0.0276	0.0011	0.0012	2.3728e-05	0.0131	0.2843	0.2706	0.0539
24	Superficial ...	0.0200	0.0016	0.0014	3.5730e-05	0.0123	0.0870	0.0770	0.0265
25	Superficial ...	0.0284	0.0017	0.0013	1.2639e-05	0.0140	0.3410	0.3268	0.0581
26	NON MELAN...	0.0199	0.0014	0.0015	4.9095e-05	0.0119	0.7480	0.7381	0.0900

Gambar 14. Nilai Rata-Rata Masing-Masing Fitur GLCM Ternormalisasi yang Digenerasi untuk Masing-Masing Citra Latih



Gambar 15. Skema pada DKNN

Dimana  $f_n(x,y)$  adalah jarak dua *tuple* (2 vektor fitur), yaitu  $X = (x_1, x_2, x_3, \dots, x_n - 1)$  dan  $X = (y_1, y_2, y_3, \dots, y_n - 1)$ . Sebelum komputasi *Euclidean distance* dilakukan, perlu adanya normalisasi untuk semua nilai pada data set atribut (set fitur) untuk menyeimbangkan seluruh nilai ke skala yang sama sehingga seluruh nilai pada masing-masing fitur berada pada rentang (0,1).

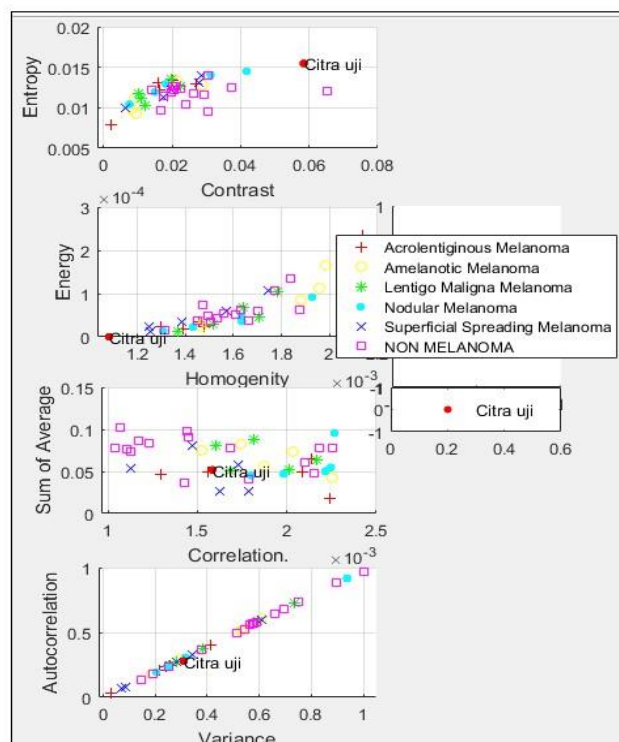
$$v' = \frac{v_n - \min_v}{\max_v - \min_v} \quad (9)$$

Dimana  $v_n$  adalah nilai fitur ke-n pada suatu deretan nilai fitur  $v$  dan  $\min_v$  adalah nilai minimum atau terkecil pada suatu deretan nilai fitur  $v$  dan  $\max_v$  adalah nilai maximum atau terbesar pada suatu deretan nilai fitur  $v$ . Salah satu citra pada pengujian memiliki pasangan-pasangan nilai rata-rata fitur ternormalisasi yang ditunjukkan pada Tabel 3.

**Tabel 3. Pasangan Fitur GLC**

Kelas Citra	$P(\text{Contrast, Entropy})$	$P(\text{Homogeneity, Energy})$	$P(\text{Correlation, Sum Abr})$	$P(\text{Variance, Autocorrelation})$
Belum Diketahui	(0.058441, 0.015444)	(0.00109, 0)	(0.0015732, 0.051025)	(0.30138, 0.27221)

Jika kedekatan pasangan-pasangan fitur pada Tabel 3 terhadap masing-masing pasangan fitur pada masing-masing citra latih pada Gambar 16 divisualisasikan pada sebuah *plane*.



**Gambar 16. Visualisasi Kedekatan Masing-Masing Pasangan Fitur Citra Uji terhadap Masing-Masing Pasangan Fitur Citra Latih**

Penggunaan banyak fitur pada fungsi *similarity* seperti *euclidean distance* dapat menyebabkan hasil klasifikasi menjadi tidak efektif. Hal ini dapat dikaitkan dengan penyimpangan dalam dimensi tinggi (*curse of dimensionality*) (Shi & Judd, 2013). Oleh sebab itu, fungsi *Euclidean distance* yang diterapkan disini adalah fungsi dalam cakupan 2D untuk masing-masing  $f_n$  pada *DKNN*. Meskipun pemilihan pasangan fitur yang sesuai masih harus diobservasi beberapa kali berdasarkan kelas output, dikarenakan citra-citra penyakit seperti ini memiliki variasi tekstur yang sangat tinggi (acak) namun dengan *DKNN* dapat menghindari prosedur-prosedur kompleks, salah satunya seperti reduksi dimensi sehingga fitur-fitur yang diinginkan dapat terpakai seluruhnya.

### 3. HASIL DAN PEMBAHASAN






















#### 3.1 Sampel citra uji dan citra latih

Citra sampel uji dan citra sampel latih dikumpulkan dari beberapa *website* penyakit kulit dan *dermatology*, yaitu *BC Cancer Agency (bccancer.bc.ca)*, *Dermatology Network New Zealand (dermnetnz.org)*, *AIM at Melanoma Foundation (aimatmelanoma.org)*, *Dermatology Information System (dermis.net)*, dan *Primary Care Dermatology Society (pcds.org)*.







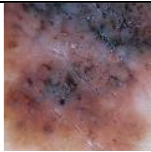


#### 3.2 Pengujian Seluruh citra uji

Pengujian dilakukan terhadap dua kategori, yakni kategori positif *melanoma* jika citra teridentifikasi sebagai *melanoma* dan pengujian terhadap kategori kelas atau golongan *melanoma* yang diuji. Kedua kategori tersebut ditunjukkan pada Tabel 4 dan Tabel 5.

**Tabel 4. Pengujian Kategori Positif Melanoma**

No	Citra	Positif Melanoma	No	Citra	Positif Melanoma	No	Citra	Positif Melanoma
1		√	11		√	21		√
2		√	12		√	22		√
3		√	13		√	23		√
4		√	14		√	24		√
5		√	15		√	25		√
6		√	16		X	26		√
7		√	17		√	27		√

Sistem Pengenalan Jenis Kanker *Melanoma* pada Citra Menggunakan *Gray Level Co-occurrence Matrices (GLCM)* dan *K-Nearest Neighbor (KNN) Classifier*

No	Citra	Positif Melanoma	No	Citra	Positif Melanoma	No	Citra	Positif Melanoma
8		√	18		√	28		√
9		X	19		√	29		√
10		√	20		√	30		√

Dari hasil pengujian pada tabel 4 diperoleh Positif Melanoma sebanyak 28 dari 30 sampel uji, sehingga diperoleh nilai akurasi positif *melanoma* sebesar :



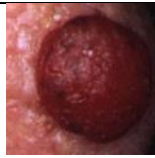




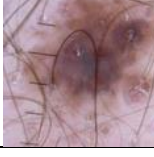
$$Accuracy (\%) = \frac{\text{Jumlah sampel citra uji yang teridentifikasi melanoma}}{\text{seluruh sampel citra uji}}$$







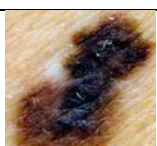



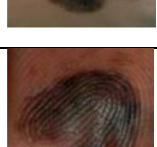

$$= \frac{28}{30} \times 100\%$$

$$= 93.33\%$$

Pengujian terhadap golongan jenis melanoma ditunjukkan pada Tabel 5 berikut.

**Tabel 5. Pengujian Kategori Jenis Melanoma**

No	Citra	Kelas Hasil Klasifikasi	Kelas Sesungguhnya	No	Citra	Kelas Hasil Klasifikasi	Kelas Sesungguhnya
1		Amelanotic Melanoma	Amelanotic Melanoma	11		Nodular	Nodular
2		Nodular Melanoma	Nodular Melanoma	12		Amelanotic Melanoma	Amelanotic Melanoma
3		Superficial Spreading Melanoma	Superficial Spreading Melanoma	13		Lentigo Melanoma	Lentigo Melanoma
4		Superficial Spreading Melanoma	Superficial Spreading Melanoma	14		Lentigo Melanoma	Lentigo Melanoma

No	Citra	Kelas Hasil Klasifikasi	Kelas Sesungguhnya	No	Citra	Kelas Hasil Klasifikasi	Kelas Sesungguhnya
5		Superficial Spreading Melanoma	Superficial Spreading Melanoma	15		Lentigo Melanoma	Superficial Spreading Melanoma
6		Acral lentiginous Melanoma	Acral lentiginous Melanoma	16		Acral lentiginous Melanoma	Superficial Spreading Melanoma
7		Acral lentiginous Melanoma	Acral lentiginous Melanoma	17		Acral lentiginous Melanoma	Nodular Melanoma
8		Superficial Spreading Melanoma	Superficial Spreading Melanoma	18		Acral lentiginous Melanoma	Superficial Spreading Melanoma
9		Acral lentiginous Melanoma	Acral lentiginous Melanoma	19		Nodular Melanoma	Amelanotic
10		Acral lentiginous Melanoma	Acral lentiginous Melanoma	20		Nodular Melanoma	Nodular Melanoma

Dari hasil pengujian tabel 5 mengenai kategori kelas atau golongan *melanoma* yang diuji terdapat kesalahan klasifikasi oleh sistem, yaitu sebanyak 5 yang tidak sesuai dari 20 kelas melanoma. Kelas yang sesuai sebanyak 15, sehingga akurasi pada kelas atau tipe *melanoma* adalah sebagai berikut :

$$\begin{aligned}
 \text{Accuracy (\%)} &= \frac{\text{Jumlah sampel citra uji yang teridentifikasi melanoma}}{\text{seluruh sampel citra uji}} \\
 &= \frac{15}{20} \times 100\% \\
 &= 75\%
 \end{aligned}$$

### KESIMPULAN

Berdasarkan hasil eksperimen, fitur-fitur *GLCM* efektif untuk dapat digunakan sebagai representasi karakteristik tekstur pada citra *melanoma* dalam hal pengidentifikasian terhadap *melanoma* tersebut. dimana diperoleh nilai akurasi sebesar 93,33% untuk kategori pengujian positif *melanoma* dan 75% untuk kategori pengujian golongan *melanoma*.



## DAFTAR PUSTAKA

- Albregtsen, F. (2018). *Statistical Texture Measures Computed from Gray Level Cooccurrence Matrices*. Oslo: Image Processing Laboratory, Department of Informatics, University of Oslo.
- Almomani, A., Alweshah, M., Alkhalaileh, S., Refai, M., & Qashi, R. (2019). Metaheuristic Algorithms-based Feature Selection Approach for Intrusion Detection. *Machine Learning for Computer and Cyber Security*, 184-208.
- Ansari, U. B., & Sarode, T. (2017). Skin Cancer Detection Using Image Processing. *International Research Journal of Engineering and Technology (IRJET)*, 2875-2881.
- Barmawi, M., Zulkarnain, A., & Hidayat, A. (2017). Implementasi Algoritma GLCM Dan MED pada Aplikasi Pendeteksi Kolesterol Melalui Iris Mata. *MIND (Multimedia, Artificial Intelligence, Networking, and Database) Journal*, 2(2), 23-42.
- Cheng, D., Zhang, S., Deng, Z., Zhu, Y., & Zong, M. (2014). kNN Algorithm with Data-Driven k Value. *Conference: International Conference on Advanced Data Mining and Applications*. China.
- Damayana, I., Atmaja, R. D., & Fauzi, H. (2016). Deteksi kanker kulit melanoma berbasis pengolahan citra menggunakan wevelet transform. *e-Proceeding of Engineering*, (pp. 4718-4723).
- Gonzalez, R., Woods, R., & Eddins, L. (2009). *Digital Image Processing Using MATLAB, 2nd Edition*. Knoxville: Gatesmark, LLC.
- Gurkirat Kaur, K. J. (2015). Automatic Detection and Segmentation of Skin Melanoma Images- An Introduction. *International Journal of Emerging Research in Management & Technology*, 120-123.
- Mesquita, D., Corona, F., Corona, F., Souza, A., & Nobre, J. (2019). Gaussian kernels for incomplete data. *Applied Soft Computing* 77, 1-22.
- Munir, R. (2004). *Pengolahan Citra Digital*. Bandung: Informatika Bandung.
- Rahman, S., Rahman, M., Al-Wadud, M., Al-Quaderi, G., & Shoyaib, M. (2016). An adaptive gamma correction for image enhancement. *EURASIP Journal on Image and Video Processing*, 1-13.
- Sebastian, B., Unnikrishnan, A., & Balakrishnan, K. (2012). Grey Level Co-Occurrence Matrices: Generalisation And Some New Features. *International Journal of Computer Science, Engineering and Information Technology (IJCEIT)*, 2(2), 151-157.

- Sheha, M. A., Mabrouk, M. S., & Sharawy, A. (2012). Automatic Detection of Melanoma Skin Cancer using Texture Analysis. *International Journal of Computer Applications*, 22-26.
- Shi, Y., & Judd, M. (2013). Finding Nearest Neighbors for Multi-Dimensional Data. *5th International Conference on Advances in Databases, Knowledge, and Data Applications* (pp. 52-). Seville, Spain: International Academy, Research, and Industry Association ( IARIA ).
- Shidnal, S. (2014). A texture feature extraction of crop field images using GLCM approach. *International Journal of Science Engineering and Advance Technology*, 1006-1010.
- Solomon, C., & Breckon, T. (2011). *Fundamentals of Digital Image Processing*. Chichester West Sussex: John Wiley & Sons Ltd.
- Widodo, R., Widodo, A., & Supriyanto, A. (2018). Pemanfaatan Ciri Gray Level Co-Occurrence Matrix (GLCM) Citra Buah Jeruk Keprok (*Citrus reticulata* Blanco) untuk Klasifikasi Mutu. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer*, 2(11), 5769-5776.
- Wu, J., Cai, Z., & Gao, Z. (2010). Dynamic K-Nearest-Neighbor with Distance and attribute weighted for classification. *2010 International Conference on Electronics and Information Engineering*. Kyoto, Japan: IEEE.
- Zhang, S., Li, X., Zong, M., Zhu, X., & Cheng, D. (2017). Learning k for kNN Classification. *ACM Transactions on Intelligent Systems and Technology*, 8(3), 1-19.