

## KLASIFIKASI INTENSITAS ANGIN SIKLON TROPIS PADA CITRA INFRAMERAH SATELIT MENGGUNAKAN METODE SVM

### CLASSIFICATION TROPICAL CYCLONE INTENSITY IN INFRARED SATELLITE IMAGERY USING SVM METHOD

Adam Agus Kurniawan<sup>1</sup>, Koredianto Usman<sup>2</sup>, R. Yunendah Nur Fuadah<sup>3</sup>

<sup>1,2,3</sup> Prodi S1 Teknik Telekomunikasi, Fakultas Teknik Elektro, Universitas Telkom

<sup>1</sup>adamaguskurniawan@student.telkomuniversity.ac.id,

<sup>2</sup>korediantousman@telkomuniversity.ac.id, <sup>3</sup>yunendah@telkomuniversity.ac.id

#### Abstrak

Dewasa ini, perubahan cuaca tidak dapat diprediksi karena adanya kejadian luar biasa akibat pemanasan global. Salah satu dampak perubahan iklim menyebabkan suburnya pertumbuhan angin siklon tropis di Bumi. Dalam mempermudah proses klasifikasi intensitas angin siklon tropis maka dibuatlah sebuah sistem yang berbasis *machine learning*. Algoritma yang digunakan dalam proses ekstraksi ciri adalah GLCM sedangkan pada proses klasifikasi adalah SVM. Pertama-tama, proses pengenalan citra inframerah dilakukan dengan mengekstraksi 14 fitur GLCM di ruang warna RGB, Ycber dan *Grayscale*. Selanjutnya, dilakukan proses kombinasi masing-masing sejumlah 3, 4 dan 5 fitur sebelum memasuki tahap klasifikasi. Pada masing-masing tahapan pengujian klasifikasi SVM dengan *coding design* OAO dan OAA akan di uji juga dengan penggunaan kernel *Gaussian*, *Linear* dan *Polynomial* termasuk juga pengaruh 3, 4 dan 5 fitur kombinasi GLCM untuk melihat pengaruhnya terhadap hasil akurasi. Dari proses pengujian ini, sistem dapat digunakan untuk mengklasifikasikan intensitas angin siklon tropis berbentuk citra inframerah dengan tingkat akurasi sebesar 88% yang sesuai dengan *saffir-simpson hurricane wind scale*.

**Kata kunci :** *Machine Learning, Siklon Tropis, Saffir-Simpson, GLCM, SVM*

#### Abstract

*Today, weather changes can't be predicted due to extraordinary events due to global warming. One of the effects of climate change has led to the proliferation of tropical cyclone events on Earth. In facilitating the process of classification of tropical cyclone intensity, a machine learning based system was created. The algorithm used in the feature extraction process is GLCM while in the classification process is SVM. First of all, the infrared image recognition process is done by extracting 14 GLCM features in the RGB, Ycber and Grayscale color spaces. Next, a combination of 3, 4 and 5 features is carried out before entering the classification stage. At each stage of SVM classification testing with OAO and OAA coding design will also be tested with the use of Gaussian, Linear and Polynomial kernels including the influence of 3, 4 and 5 GLCM combination features to see the effect on the results of accuracy. From this testing process, the system can be used to classify tropical cyclone intensity in the form of infrared images with an accuracy rate of 88% which corresponds to the saffir-simpson hurricane wind scale.*

**Keywords:** *Machine Learning, Tropical Cyclone, Saffir-Simpson, GLCM, SVM*

#### 1. Pendahuluan

Pada era yang serba digital seperti saat ini, kecerdasan buatan telah beredar memperkenalkan dirinya dengan cepat dan luas. *Machine learning* telah menjadi kebutuhan yang sangat penting dalam berbagai macam sektor. Misalnya, pada bidang meteorologi dan klimatologi *machine learning* dapat diterapkan untuk mengenali intensitas dari angin siklon tropis yang di dapatkan dari citra inframerah satelit. Teknologi ini memanfaatkan kecerdasan buatan untuk mengenali pola warna dari citra inframerah yang memuat informasi temperatur awan.

Menurut sejarah, sekitar 90% angin siklon tropis yang telah terjadi sangat mematikan, karena ukurannya yang sangat besar disertai angin yang sangat kencang, hujan deras berjam-jam bahkan berhari-hari. Dampak lain angin siklon secara tidak langsung juga mengakibatkan terbentuknya lebih banyak awan-awan konvektif dan menyerap persediaan udara lembab padaradius tertentu disekitarnya. Menurut penelitian sebelumnya, bahwa pemanasan global akan menyebabkan intensitas rata-rata angin siklon tropis akan bergeser ke arah badai yang lebih kuat dengan peningkatan intensitas 2-11% pada tahun 2100 [1].

Karena terdapat kemungkinan peningkatan intensitas angin siklon yang cukup menakutkan dimasa yang akan datang, maka dengan memanfaatkan *machine learning* kita dapat mengolah dan dilakukan analisa data citra inframerah yang didapatkan dari berbagai macam satelit cuaca untuk merancang sistem yang mampu mengenali dan mengkategorikan intensitas angin siklon tropis. Sehingga proses identifikasi dan kemungkinan dampak yang akan diakibatkan oleh siklon tropis ini akan dapat segera diketahui. Selain itu, sistem ini juga bisa juga dimanfaatkan sebagai *early warning* terhadap fenomena siklon tropis yang sedang terjadi.

Pengujian penelitian ini akan memanfaatkan algoritma *machine learning* sebagai metode untuk proses pengenalan dan klasifikasi. Citra inframerah siklon tropis sendiri secara kasat mata dapat dibedakan dari perbedaan warna kehijauan dan kemerahannya yang mempresentasikan temperatur awan. GLCM merupakan algoritma yang akan di pakai pada proses pengenalan, dimana algoritma ini dapat diandalkan untuk mengekstraksi ciri warna dan tekstur. Sedangkan, SVM digunakan sebagai metode untuk mengklasifikasikan citra inframerah berdasarkan kelas yang sesuai dengan *saffir-simpson hurricane wind scale*. Dari seluruh proses pengujian ini, sistem mampu untuk mengklasifikasikan intensitas siklon tropis yang sesuai *saffir-simpson hurricane wind scale* dengan tingkat akurasi sebesar 88%.

## 2. Konsep Dasar

### 2.1 Pengertian

Siklon tropis (atau hurikan, angin puyuh, badai tropis, taifun atau angin ribut tergantung pada daerah dan intensitasnya) adalah sebuah jenis sistem tekanan udara rendah yang terbentuk secara umum di daerah tropis[2]. Angin ini merupakan faktor terpenting dari sistem distribusi atmosfer Bumi, karena mampu memindahkan panas dari daerah khatulistiwa ke garis lintang yang lebih tinggi. Berdasarkan strukturnya, siklon tropis adalah daerah raksasa aktivitas awan, angin dan badai petir yang berkisar [3]. Hal yang membedakan angin siklon tropis dengan kejadian meteorologis lainnya adalah siklon tropis mampu melepaskan panas akibat kondensasi dari uap air yang mengembang pada lapisan atmosfer yang tinggi.

### 2.2 Skala Intensitas Angin Siklon Tropis (*Saffir-Simpson Hurricane Wind Scale*)

Siklon tropis secara resmi telah diberikan kategori sesuai dengan skala intensitasnya yang bergantung pada kecepatan angin, indeks daya disipasi, indeks energi kinetik terpadu dan indeks keparahan badai. Siklon tropis yang terjadi di antara belahan bumi utara ke timur dari anti-meridian, secara resmi diawasi oleh *National Hurricane Center* atau *The Central Pacific Hurricane Center*. Pada wilayah ini, siklon tropis didefinisikan sebagai pusaran yang hangat, gangguan sinoptik non-frontal yang berkembang di atas perairan tropis atau sub-tropis dengan konveksi atmosfer yang teratur dan memiliki pusat sirkulasi tertutup yang jelas.

Jika terjadi sebuah gangguan cuaca tropis yang mampu menyebabkan badai tropis di daratan dalam waktu 48 jam, maka hal ini bisa dikatakan sebagai potensi badai tropis. Potensi badai tropis yang semakin intensif dan menciptakan angin yang lebih besar dari 64 knot atau 119 km/jam, maka disebut sebagai badai dan dapat diklasifikasikan pada *saffir-simpson hurricane wind scale* yang sesuai dengan gambar 1.

Saffir–Simpson scale

Category	Wind speeds			
	m/s	knots (kn)	mph	km/h
Five	≥ 70 m/s	≥ 137 kn	≥ 157 mph	≥ 252 km/h
Four	58–70 m/s	113–136 kn	130–156 mph	209–251 km/h
Three	50–58 m/s	96–112 kn	111–129 mph	178–208 km/h
Two	43–49 m/s	83–95 kn	96–110 mph	154–177 km/h
One	33–42 m/s	64–82 kn	74–95 mph	119–153 km/h


Gambar 1 *Saffir-Simpson Hurricane Wind Scale*

### 2.3 GLCM (Gray Level Co-occurrence Matrix)

GLCM merupakan metode paling awal untuk proses ekstraksi fitur tekstur yang dikemukakan oleh Haralick di tahun 1973 [4]. GLCM digunakan secara luas untuk banyak keperluan dalam aplikasi tekstur analisis dan masih menjadi fitur ekstraksi yang paling penting dalam domain tekstur analisis.

#### a. Konstruksi Matriks Kookurensi Tradisional

*Grey Level Cooccurrence Matrix* didefinisikan oleh Haralick sebagai sebuah matrik persegi  $G$  dengan  $N$  adalah total nilai dari tingkat keabuan sebuah citra, dimana masukan  $(i,j)$  dari  $G$  merepresentasikan seberapa banyak sebuah piksel dengan intensitas  $i$  bertetangga dengan sebuah piksel dengan intensitas  $j$ . Sesuai dengan gambar 1 ketetangaan secara definisi dapat berlangsung di empat arah sebagai berikut yakni secara horisontal, vertikal, diagonal kiri dan diagonal kanan.



**Gambar 2** Arah ketetangaan untuk menghitung fitur tekstur Haralick [4].

#### b. Citra Grayscale

Dalam memahami konsep matriks kookurensi ke dalam ruang Euclidean dengan dimensi  $N$ , sebuah model matematis untuk konsep diatas sangat diperlukan. Kita anggap  $Z^n$  sebagai set bersama, secara matematis dapat ditulis  $Z^n = Z \times Z \times \dots \times Z$ , dimana  $Z$  merupakan set dari semua nilai integer. Citra  $I$  adalah bentuk fungsi dari bagian  $Z^n$  ke  $Z$ , jika  $f: I \rightarrow Z$  dimana  $I \subset Z^n$ . Jika  $X \in I$ , maka  $X$  ditetapkan sebuah nilai integer  $Y$  seperti  $Y = f(X)$ .  $Y$  disebut sebagai intensitas piksel  $X$ . Citra yang dikatakan grayscale jika dalam dimensi sebesar  $N$  memuat  $Z^n$ . c

#### c. Matriks Kookurensi

GLCM didefinisikan merupakan sebuah matriks persegi  $G_d$  dengan ukuran  $N$ , dimana  $N$  merupakan jumlah nilai dari tingkat keabuan dari sebuah citra. Nilai masukan  $(i,j)$  dari  $G_d$  menunjukkan berapa kali sebuah piksel  $X$  yang memiliki nilai intensitas  $i$  dipisahkan dari piksel  $Y$  dengan nilai intensitas  $j$  pada jarak  $k$  tertentu dan arah  $d$  tertentu.

$$\begin{pmatrix} 0 & 0 & 1 \\ 0 & 1 & 2 \\ 0 & 2 & 3 \end{pmatrix}, \begin{pmatrix} 1 & 2 & 1 \\ 0 & 2 & 3 \\ 0 & 1 & 2 \end{pmatrix} \text{ dan } \begin{pmatrix} 1 & 3 & 0 \\ 0 & 3 & 1 \\ 3 & 2 & 1 \end{pmatrix}$$

**Gambar 3** Contoh matriks citra 3 dimensi [4].

$$G_d = \begin{pmatrix} 1 & 3 & 2 & 1 \\ 0 & 0 & 3 & 1 \\ 0 & 1 & 0 & 3 \\ 1 & 1 & 1 & 0 \end{pmatrix}$$

**Gambar 4** Hasil sementara matriks kookurensi citra 3 dimensi [4].

$$G_d = \begin{pmatrix} 1 & 0 & 0 & 1 \\ 3 & 0 & 1 & 1 \\ 2 & 3 & 0 & 1 \\ 1 & 1 & 3 & 0 \end{pmatrix} = G'_d$$

**Gambar 5** Hasil transpose matrik kookurensi  $G_d$  [4].

Sebuah citra memiliki matriks 3 dimensi dengan ukuran  $3 \times 3 \times 3$  sesuai dengan gambar 2 yang terbagi menjadi 3 bagian. Sesuai gambar 3, hasil sementara matriks kookurensi 3 dimensi dari

$G_d$  dengan arah  $d = (1,0,0)$  adalah matriks dengan ukuran  $4 \times 4$ . Sementara untuk mengetahui hasil pasti matriks kookurensi, maka dilakukanlah proses transpose pada matriks  $G_d$  sehingga didapatkan matriks  $G_d'$  sesuai dengan gambar 4.


d. Normalisasi Matriks Kookurensi

Menilik bahwa  $\sum_i \sum_j G_d(i,j)$  yang merupakan total jumlah dari pasangan nilai kookurensi di  $G_d$ . Jika  $GN_d(i,j) = (1/N) G_d(i,j)$ ,  $GN_d$  merupakan sebuah normalisasi matriks kookurensi, dimana nilai masukan pada  $(i,j)$  dari  $GN_d$  adalah probabilitas gabungan dari piksel kookurensi dengan intensitas  $i$  dan piksel dengan intensitas  $j$  terpisahkan oleh jarak sebesar  $k$  di arah  $d$  tertentu.

Berdasarkan pada GLCM yang telah dilakukan normalisasi, Haralick mengusulkan 14 fitur tekstur statistik yang menunjukkan hasil ekstraksi dari matriks ko-okurensi. Berdasarkan [5], 14 fitur itu adalah *Angular Second Moment (Energy)*, *Contrast*, *Correlation*, *Variance*, *Inverse Difference Moment (Homogeneity)*, *Sum Average*, *Sum Variance*, *Sum Entropy*, *Entropy*, *Difference Variance*, *Difference Entropy*, *Information Measure of Correlation I*, *Information Measure of Correlation II* dan *Maximal Correlation Coefficient*.

## 2.4 SVM (Support Vector Machine)

Algoritma SVM termasuk tipe *supervised machine learning* yang umumnya digunakan untuk masalah pengklasifikasian. SVM dikembangkan dalam susunan statistik teori pembelajaran [6], mereka telah berhasil membuat beberapa aplikasi seperti pengenalan wajah hingga pemrosesan data biologikal untuk diagnosis medis. Di dalam algoritma ini, kita kelompokkan setiap item data sebagai sebuah titik di dalam dimensi sebesar  $N$ , dimana  $N$  merupakan jumlah fitur yang kita miliki. Setiap nilai dari fitur memiliki nilai untuk koordinat tertentu, kemudian dapat dilakukan klasifikasi dengan menemukan *hyper-plane* yang memisahkan dua kelas. *Hyper-plane* merupakan garis batas yang membantu menentukan klasifikasi dari sebuah data seperti pada gambar 6.



Gambar 6 Garis batas *hyper-plane*

### 2.4.1 Multi-Class SVM

Saat ini terdapat dua tipe pendekatan untuk multi-class SVM, yang pertama dengan membangun dan mengkombinasikan beberapa klasifikasi binari. Persamaan untuk menyelesaikan masalah pada multi-class SVM pada salah satu langkahnya memiliki variabel yang sama dengan jumlah total pada kelasnya. Oleh karena itu, beberapa klasifikasi binari harus disusun sebelum memunculkan masalah optimalisasi yang besar. Pengujian yang dilakukan terbatas pada data set yang kecil, yang kemudian dilakukan performansi dengan metode berdasarkan klasifikasi binari seperti *One-Again-One (OAO)* dan *One-Again-All (OAA)*.

Metode *One-Again-All (OAA)* menyusun  $k$  model SVM dimana  $k$  adalah sejumlah kelas. Nilai data sejumlah  $m$  SVM dilakukan proses *train* dengan semua contoh kelas, data sejumlah  $m$  yang memiliki label positif dan label negatif. Metode umum lainnya adalah *One-Again-One (OAO)*, dimana metode ini menyusun sejumlah  $k(k-1)/2$  klasifikasi yang setiap satu data akan dilatih pada data dari dua buah kelas. Kemudian, dilakukan prediksi nilai  $x$  pada kelas dengan pemilihan paling besar, dimana proses pemilihan ini menggunakan pendekatan yang di sebut strategi *Max Wins*.

### 2.4.2 Kernel Functions

*Kernel functions* digunakan untuk mengubah data latih yang memiliki nilai non-linier ke dalam persamaan linier yang memiliki dimensi yang besar. Berikut ini adalah beberapa fungsi kernel paling populer yang sering digunakan:

a. *Radial Basis Functions* (RBF)

Persamaan (1) merupakan bentuk rumus dari kernel *Gaussian*. Dimana, titik N dengan sejumlah  $\vec{x}_n$  data sampel berasal dari data latih dengan ketentuan  $\|\vec{x} - \vec{x}_n\|$  merupakan jarak *Euclidean* dari kumpulan titik-titik  $\vec{x}_n$  [7].

$$g(\vec{X}) = \sum_{n=1}^N \vec{W}_n^T f(\|\vec{X} - \vec{x}_n\|) \tag{1}$$

b. *Linear Kernels*

Bentuk persamaan kernel linier dapat dilihat pada persamaan (2), diskriminan di dalam ruang  $k(\vec{z}, \vec{x}) = f(\vec{z}^T) f(\vec{x})$  bisa di pelajari, dimana  $\vec{w}$  di gunakan untuk mempelajari nilai pada data latih [7].

$$k(\vec{w}, \vec{x}) = \vec{w}^T \vec{x} \tag{2}$$

c. *Polynomial Kernels*

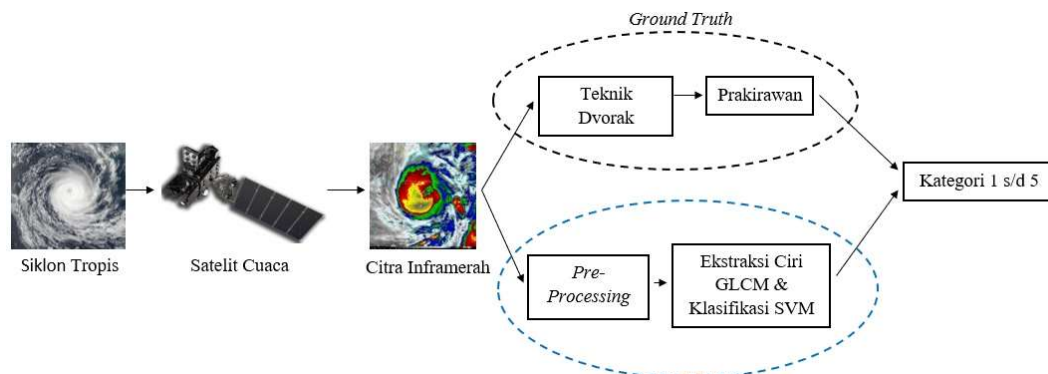
Persamaan (3) merupakan rumus dari kernel *Polynomial*, dimana, n adalah order dari sebuah kernel dan c adalah nilai konstan yang memungkinkan pertukaran yang bisa mempengaruhi nilai order tertinggi dan terendah [7].

$$k(\vec{x}, \vec{z}) = (\vec{z}^T \vec{x} + c)^n \tag{3}$$

### 3. Perancangan Sistem

#### 3.1 Gambaran Umum Sistem

Sesuai dengan gambar 7 di bawah menunjukkan gambaran umum sistem yang akan dibuat, dimana data masukan berupa citra inframerah angin siklon tropis yang di dapatkan dari satelit cuaca kemudian dilakukan proses pengolahan terhadap citra masukan tersebut seperti *pre-processing*, ekstraksi ciri dan klasifikasi sesuai dengan algoritma *machine learning* yang akan digunakan.



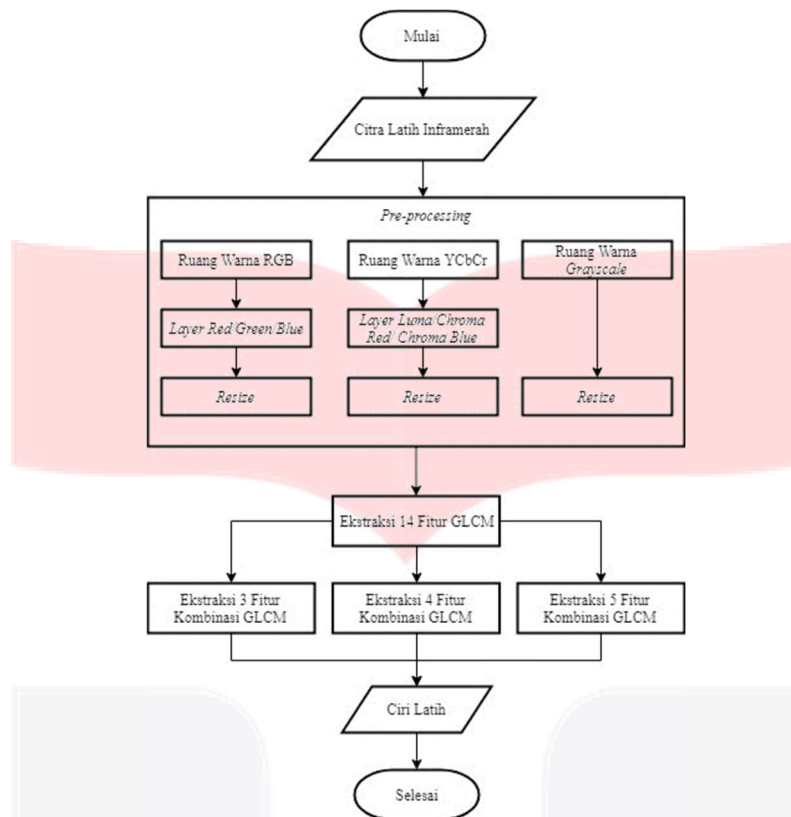
Gambar 7 Gambaran Umum Sistem

#### 3.2 Diagram Alur Sistem

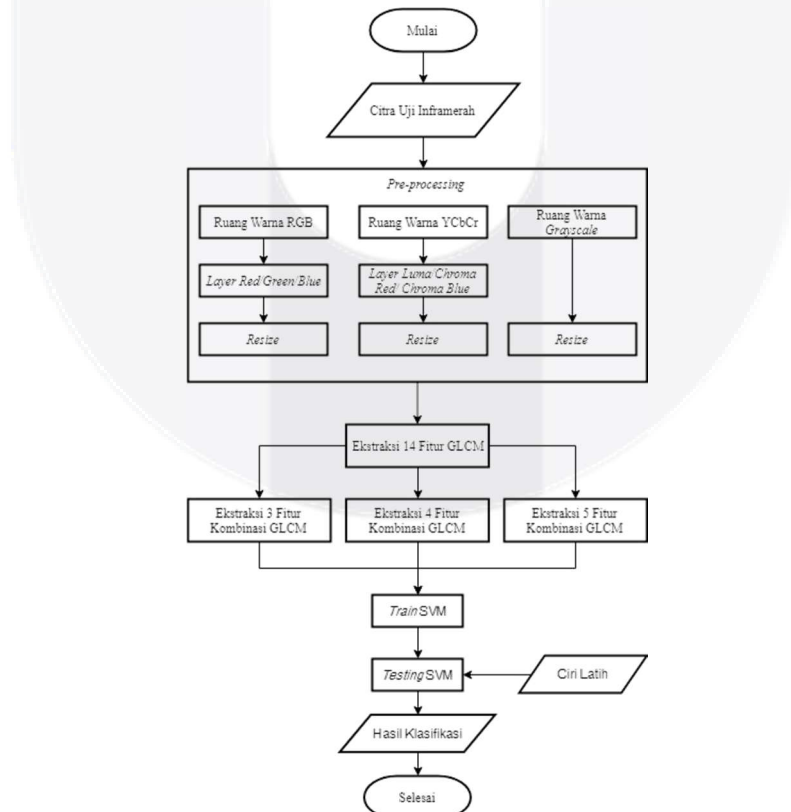
Sesuai dengan gambar 8 bahwa pada setiap citra inframerah dari angin siklon tropis yang telah dikumpulkan sebagai data latih, pertama-tama akan dilakukan proses membaca data. Data citra latih yang telah terbaca selanjutnya akan dilakukan proses *pre-processing* sebelum memasuki sistem utama, dimana dalam proses ini akan dilakukan perubahan terhadap ruang warna (RGB, YCbCr dan *Grayscale*) sebelum dilakukan perubahan ukuran piksel citra latih. Setelah itu, data citra latih akan di proses menggunakan metode GLCM untuk mengekstraksi sebanyak 14 fiturnya. Data ekstraksi 14 fitur GLCM di proses untuk dilakukan proses kombinasi sebanyak 3, 4 dan 5 kombinasi fitur. Data ekstraksi fitur tekstur dari masing-masing kombinasi ini kemudian di simpan ke dalam ciri latih untuk kemudian dijadikan sebagai data acuan dalam proses klasifikasi menggunakan metode SVM.

Diagram alir pada gambar 9 menunjukkan proses metode klasifikasi SVM, dimana proses ekstraksi ciri pada citra uji tidaklah berbeda dengan proses ekstraksi ciri pada citra latih. Namun, setelah proses kombinasi 3,4 dan 5 fitur kombinasi GLCM maka algoritma akan melakukan proses *train* menggunakan metode SVM terhadap data ekstraksi ciri pada masing-masing citra uji. Kemudian dilakukan proses prediksi dengan membandingkan data keluaran dari proses *train* SVM

data uji dengan data keluaran dari proses ekstraksi ciri data latih hingga muncul hasil akhir berupa hasil klasifikasi.



Gambar 8 Diagram alir pengenalan citra siklon tropis menggunakan metode GLCM



Gambar 9 Diagram alir klasifikasi intensitas siklon tropis menggunakan metode SVM

#### 4. Performansi sistem

##### 4.1 Pengaruh *Layer* Ruang Warna Terhadap Akurasi

Pada tabel 1 terlihat bahwa lapisan pada masing-masing ruang warna cukup mempengaruhi proses pengenalan hingga klasifikasi, terbukti pada satu ruang warna RGB saja yang bekerja pada lapisan merah, hijau dan biru misalnya memiliki akurasi yang berbeda. Begitu pula, antar ruang warna misalnya pada ruang warna YCbCr lapisan *Luminance* memiliki akurasi yang berbeda pada ruang warna *Grayscale*. Sehingga didapatkan akurasi terbaiknya pada ruang warna RGB lapisan hijau sebesar 72%.

**Tabel 1** Pengaruh *Layer* Ruang Warna Terhadap Akurasi

Ruang Warna	<i>Layer</i>	Sudut ( $\theta$ )	Jarak (d)	Fitur Kombinasi	Akurasi (%)
RGB	<i>Red</i>	0	2	5	56
RGB	<i>Green</i>	0	2	5	72
RGB	<i>Blue</i>	0	2	5	48
YCbCr	<i>Luminance</i>	0	2	5	60
YCbCr	<i>Chroma Blue</i>	0	2	5	64
YCbCr	<i>Chroma Red</i>	0	2	5	60
<i>Grayscale</i>	<i>Grayscale</i>	0	2	5	60

##### 4.2 Pengaruh Fitur Kombinasi Terhadap Akurasi

Terlihat pada tabel 2 menunjukkan performansi sistem sangat dipengaruhi oleh fitur kombinasi algoritma GLCM yang dipakai sebagai metode ekstraksi ciri. Pada pengujian ini didapatkan bahwa sistem bekerja dengan baik pada ruang warna RGB lapisan hijau dengan 4 dan 5 fitur kombinasi yang menghasilkan akurasi sebesar 72%.

**Tabel 2** Pengaruh Fitur Kombinasi Terhadap Akurasi

Ruang Warna	Sudut ( $\theta$ )	Jarak (d)	<i>Layer</i>	Akurasi (%)		
				3 Fitur Kombinasi	4 Fitur Kombinasi	5 Fitur Kombinasi
RGB	0	2	<i>Green</i>	52	72	72
YCbCr	0	2	<i>Chroma Red</i>	64	68	60
<i>Grayscale</i>	0	2	<i>Grayscale</i>	44	60	60

##### 4.3 Pengaruh Sudut dan Jarak Terhadap Akurasi

Berdasarkan tabel 3 menunjukkan bahwa penggunaan jarak 1 dan 2 dengan sudut tertentu sangat mempengaruhi performansi sistem sehingga menghasilkan akurasi yang beragam. Pada tabel 3 dapat dilihat bahwa sistem bekerja dengan baik pada ruang warna RGB lapisan hijau dengan  $d = 2$  dan  $\theta = 0$  dan  $45$  yang menghasilkan akurasi tertinggi sebesar 72% dibanding dengan pengujian pada jarak dan sudut lainnya.

**Tabel 3** Pengaruh Sudut dan Jarak Terhadap Akurasi

Ruang Warna & <i>Layer</i>	Fitur Kombinasi	Akurasi (%)							
		d = 1				d = 2			
		$\theta = 0$	$\theta = 45$	$\theta = 90$	$\theta = 135$	$\theta = 0$	$\theta = 45$	$\theta = 90$	$\theta = 135$
RGB ( <i>Green</i> )	5	60	60	60	68	72	72	60	64
YCbCr ( <i>Chroma Red</i> )	5	56	56	40	56	60	60	60	64
<i>Grayscale</i>	5	56	52	48	48	60	60	48	48

#### 4.4 Pengaruh Coding Design & Kernel Terhadap Akurasi

Pada tabel 4 dapat dilihat bahwa penggunaan *coding design* OneAgainsOne (OAO) dan OneAgainsAll (OAA) pada masing-masing kernel *Gaussian*, *Linear* dan *Polynomial* menghasilkan akurasi yang bervariasi. Selain itu, penggunaan *coding design* dan kernel ini juga mampu untuk meningkatkan performansi sistem. Terbukti pada pengujian ruang warna RGB lapisan hijau yang bekerja pada *coding design* OAA serta kernel *Gaussian* menghasilkan akurasi tertinggi sebesar 88%.

**Tabel 4** Pengaruh Coding Design & Kernel Terhadap Akurasi

Ruang Warna	Layer	Sudut ( $\theta$ ), Jarak, Fitur Kombinasi	Coding Design	Akurasi (%)		
				Kernel <i>Gaussian</i>	Kernel <i>Linear</i>	Kernel <i>Polynomial</i>
RGB	<i>Green</i>	0, 2, 5	OAO	84	80	84
YCbCr	<i>Chroma Red</i>	0, 2, 5	OAO	68	68	68
RGB	<i>Green</i>	0, 2, 5	OAA	88	56	72
YCbCr	<i>Chroma Red</i>	0, 2, 5	OAA	72	52	60

## 5 Kesimpulan dan Saran

### 5.1 Kesimpulan

Dari hasil pengujian dan analisis yang telah dilakukan pada sistem klasifikasi angin siklon tropis pada citra inframerah satelit, kesimpulan yang dapat diambil adalah pengujian klasifikasi menghasilkan akurasi terbaik sebesar 88% yang dihasilkan oleh fitur *Energy*, *Contrast*, *Correlation*, *Variance*, *Homogeneity* hasil ekstraksi matriks ko-okurensi  $d = 2$  dan sudut ( $\theta$ ) = 0 yang bekerja pada ruang warna RGB layer *green* menggunakan klasifikasi Multi-SVM dengan *coding design* OAA dan kernel *Gaussian*.

### 5.2 Saran

Penulis merekomendasikan saran yang perlu di perhatikan dalam pelaksanaan penelitian ini seperti proses komputasi pada penelitian ini perlu dipertimbangkan untuk menggunakan perangkat keras yang memiliki spesifikasi cukup bagus sehingga proses komputasi tidak menghabiskan atau memberatkan *resources* pada perangkat keras komputer yang digunakan. Serta, citra inframerah yang tersedia pada lembaga penelitian cuaca RAMMB terkadang memiliki kualitas yang buruk akibat pengaruh eksternal transmisi antara penerima dan pengirim, sehingga perlu diperhatikan untuk meningkatkan kualitas citra.

### Daftar Pustaka

- [1] J. Mcbride, G. Holland, J. C. L. Chan, and C. W. Landsea, "Tropical Cyclones and Climate Change," *Nature Geoscience*, 2010.
- [2] M. T. Montgomery and B. F. Farrell, "Tropical Cyclone Formation," *Journal of the Atmospheric Sciences*, 1992.
- [3] Wikipedia, "Siklon Tropis," Aug. 2018. [Online] Available at : <https://id.wikipedia.org/wiki/Siklontropis> [Accessed 08 Sep. 2018].
- [4] B. S. Vadakkenveettil, "Grey Level Co-Occurrence Matrices: Generalisation and Some New Features," *International Journal of Computer Science, Engineering and Information Technology (IJCEIT)*, 2012.
- [5] R. M. Haralick, K. Shanmugan, and I. Dinstein, "Textures Features for Image Classification," *IEEE TRANSACTIONS ON SYSTEMS, MAN AND CYBERNETICS*, 1973.
- [6] A. B. Witarto, D. Handoko, and A. S. Nugroho, "Support Vector Machine (Teori dan Aplikasinya dalam Bioinformatika)," *Kuliah Umum Ilmu Komputer*, 2003.
- [7] J. L. Crowley, "Kernel Functions and Support Vector Machines," *Intelligent Systems: Reasoning and Recognition*, 2016.