

KLASIFIKASI KANKER USUS BESAR MENGGUNAKAN METODE EKSTRAKSI CIRI *PRINCIPAL COMPONENT ANALYSIS* DAN KLASIFIKASI *SUPPORT VECTOR MACHINE*

(*Classification of Colon Cancer Using the Extraction Method of Principal Component Analysis and Classification Support Vector Machine*)

Agung Aditama Putra¹, Ir. Rita Magdalena, M.T.², R. Yunendah Nur Fuadah, S.T., M.T.³

^{1,2,3}Prodi S1 Teknik Telekomunikasi, Fakultas Teknik Elektro, Universitas Telkom

¹agungaditama@students.telkomuniversity.ac.id, ²ritamagdalen@telkomuniversity.ac.id ,

³yunendah@telkomuniversity.ac.id

Abstrak

Kanker kolektal adalah salah satu jenis kanker ganas yang terdapat pada usus besar (kolon) dan bagian paling bawah dari usus besar yang terhubung ke anus (rectum) karena gaya hidup yang tidak sehat. Ada beberapa jenis kanker usus besar yang menyerang manusia yaitu *Sarcoma*, *Lymphoma*, dan *Carcinoma*. Sistem yang dirancang ini untuk melakukan sebuah simulasi klasifikasi terhadap citra usus besar menggunakan metode *Support Vector Machine* (SVM) sebagai klasifikasi ciri. Dan *Principal Analysis Component* (PCA) sebagai ekstraksi ciri. Hasil dari Tugas Akhir ini adalah suatu sistem yang mampu melakukan identifikasi jenis penyakit kanker usus besar yang terdiri dari penyakit *carcinoma*, *lymphoma*, dan usus normal pada manusia. Sistem ini memiliki performansi nilai akurasi tertinggi 74.4% dengan waktu komputasi 6,4654 detik menggunakan 108 data citra latih dan 60 citra uji. Hasil ini menggunakan data uji ukuran 64×64 piksel, citra warna green, parameter statistik *Entropy*, *Mean*, dan *Skewness* pada PCA. Pada klasifikasi *Support Vector Machine* (SVM) menggunakan *Kernel Radian Basis Function* (RBF), dan pembagian *multiclass One-Against-One* (OAO).

Kata Kunci: Usus Besar, kanker kolektal, PCA, SUPPORT VECTOR MACHINE (SVM)

Abstract

Colorectal cancer is one type of malignant cancer found in the large intestine (colon) and the lowest part of the large intestine that is connected to the anus (rectum) due to an unhealthy lifestyle. There are several types of colon cancer that attack humans, namely *Sarcoma*, *Lymphoma*, and *Carcinoma*. The design of this system to simulate the classification of large intestine images using the *Support Vector Machine* (SVM) method as a feature classification. And *Principal Analysis Component* (PCA) as feature extraction. The results of this Final Project are a system that can identify types of colon cancer consisting of normal carcinoma, lymphoma and intestinal disease in humans. This system has the highest accuracy value of 74.4% with a computing time of 6.4654 seconds using 108 training image data and 60 test images. These results use 64×64 pixel test data, green color images, *Entropy*, *Mean*, and *Skewness* statistical parameters on PCA. The *Support Vector Machine* (SVM) classification uses the *Kernel Radian Basis Function* (RBF), and the *multiclass One-Against-One* (OAO) distribution.

Keywords: Colon, colorectal cancer, PCA, SUPPORT VECTOR MACHINE (SVM)

1. Pendahuluan

Kanker adalah penyebab utama kematian kedua secara global, sekitar 8,8 juta kematian pada tahun 2015. Secara global, hampir 1 dari 6 kematian disebabkan oleh kanker dimana 774.000 kematian disebabkan oleh kanker usus besar atau kolektal [1]. Kanker usus besar (*colorectal cancer*) merupakan salah satu jenis kanker yang menduduki peringkat 3 terbanyak diderita di Indonesia baik perempuan maupun laki-laki.

Kanker yang sering terjadi pada usus besar manusia biasanya adalah *lymphoma* dan *Carcinoma*. Pengklasifikasian dan pendeteksian sejak dini pada penyakit kanker bisa memperkecil resiko perkembangan kanker ke tingkat stadium yang lebih tinggi lagi, sehingga memungkinkan penderita untuk sembuh dan tidak berujung pada kematian. Saat ini pendeteksian dan pengklasifikasian dilakukan secara manual, yaitu dengan cara menaruh hasil sel di atas preparat dilihat dengan mikroskop untuk menentukan apakah sel tersebut kanker dengan melihat strukturnya lalu dibandingkan dengan sel yang sehat. Pendiagnosaan dengan cara tersebut sangat berhubungan dengan penglihatan dokter, kesalahan atau ketelitian penglihatan sangat mempengaruhi hasil diagnosa [1].

Berdasarkan latar belakang tersebut, penulis membuat suatu rancangan system berbasis aplikasi Matlab untuk membantu proses identifikasi jenis penyakit kanker usus besar menggunakan ekstraksi ciri *Principal Component Analysis* (PCA), dan klasifikasi *Support Vector Machine* (SVM). Dalam tugas akhir ini menggunakan referensi dari tugas akhir sebelumnya. Pada tahun 2018, Ocky Tiaramukti mengembangkan sistem klasifikasi kanker usus besar menggunakan metode *Principal Component Analysis* (PCA) sebagai ekstraksi ciri dan metode klasifikasi *K-Nearest Neighbor* (K-NN). Metode yang diusulkan ini menghasilkan nilai akurasi 68,52% [8]. Pada tahun 2018 Nadya Viana mengembangkan sistem pengenalan wajah 3D menggunakan metode *Iterative Closet Point* (ICP) dan *Support Vector Machine* (SVM) sebagai klasifikasi. Metode yang diusulkan ini menghasilkan nilai akurasi 97,56% [14].

2. Konsep Dasar

2.1 Usus Besar


Usus besar adalah pencernaan terakhir pada manusia yang bekerja menghancurkan makanan menjadi asam amino, glukosa, lemak, air, vitamin dan mineral serta bahan sisa hasil pencernaan terakhir yang dibuang menjadi feses. Sedangkan yang bermanfaat akan disalurkan kembali ke seluruh tubuh. Fungsi utama usus besar ialah untuk mengabsorpsi air kembali dan untuk mengeluarkan mucus yang berfungsi untuk melumasi dan membantu mengeluarkan feses beserta gas-gas [2].

2.2 Kanker Usus Besar

Kanker Usus Besar Kanker usus besar atau disebut juga kanker kolorektal merupakan salah satu jenis kanker ganas yang terjadi pada permukaan usus besar (kolon) dan rectum (bagian usus paling bawah sampai anus/dubur) karena pengaruh lingkungan dan gaya hidup yang tidak sehat [3]. Penyebab kanker usus besar bisa dikarenakan berbagai faktor, seperti zat karsinogenik, efek lingkungan atau genetik [4]. Sebagian besar kanker kolorektal adalah tipe kanker adenocarcinomas (Kanker yang berasal dari sel yang membuat dan melepaskan lendir atau cairan lainnya) [3]. Adapun jenis kanker kolektal yang akan dibahas, yaitu:

2.2.1 Carcinoma

Carcinoma adalah kanker yang dimulai di jaringan yang melapisi permukaan dalam atau luar tubuh, umumnya muncul dari sel-sel yang berasal dari lapisan kuman endodermal atau ectodermal selama embriogenesis. Lebih spesifiknya, *Carcinoma* adalah jaringan tumor berasal dari sel epitel yang berubah atau rusak sehingga sel-sel tersebut menjadi berubah dan mulai menunjukkan sifat ganas abnormal. Kanker ini umumnya menyerang manusia yang sudah lanjut usia dan sangat jarang terjadi pada anak-anak [5].



Gambar 1 Sel kanker Carcinoma [6]

2.2.2 Lymphoma


Lymphoma adalah kanker pada sel-sel limfatik dari sistem kekebalan tubuh. Biasanya, *lymphoma* hadir sebagai soloid tumor sel limfoid. Pengobatan mungkin melibatkan kemoterapi dan dalam beberapa kasus radioterapi dan/atau transplantasi sumsum tulang belakang, dan dapat disembuhkan tergantung pada histologi, jenis dan tahap penyakit [7].



Gambar 2 Sel kanker
Lymphomna [7]

2.2.3 Normal

Berikut ini adalah gambar dari sel usus normal yang diamati dari mikroskop.



Gambar 3 Sel usus normal

2.3 Principal Component Analysis (PCA)

PCA adalah metode dengan melakukan pemetaan atau transformasi set data dari dimensi lama ke dimensi baru (yang relatif berdimensi lebih rendah) dengan memanfaatkan teknik aljabar linear tanpa memerlukan masukan parameter tertentu dalam memberikan keluaran hasil pemetaannya [8]. Prinsip dasar dan algoritma PCA adalah memproyeksikan image ke dalam bidang ruang eigen-nya [9]. Langkah-langkah yang dilakukan dalam proses PCA adalah sebagai berikut [10].

1. Mengolah Citra input

Dapatkan sejumlah m citra pelatihan yang direpresentasikan dalam I_i dimana $i = 1, 2, 3, \dots, m$. Masing-masing citra pelatihan mempunyai ukuran $a \times b$ piksel dan hasil perkalian $a \times b$ tersebut akan direpresentasikan ke dalam N . Representasi setiap citra I_i menjadi vektor Γ_i sebagai berikut.

$$\begin{bmatrix} a_{1,1} & a_{1,2} & \dots & a_{1,b} \\ a_{2,1} & a_{2,2} & \dots & a_{2,b} \\ \vdots & \vdots & \ddots & \vdots \\ a_{a,1} & a_{a,2} & \dots & a_{a,b} \end{bmatrix} \longrightarrow \begin{pmatrix} a_1 \\ \vdots \\ a_{N \times m} \end{pmatrix} \quad (1)$$

m = jumlah citra pelatihan, dan n = jumlah piksel hasil kali a dan b

2. Mencari Citra ciri

Citra rata-rata adalah rata-rata dari semua piksel citra-citra training. Misalnya diketahui m adalah jumlah citra pelatihan dengan indeks I maka rata-ratanya adalah

$$\mu = \frac{1}{m} \sum_{i=1}^m \Gamma_i \quad (2)$$

μ = matriks rata-rata. m = jumlah sampel citra pelatihan. hasil dari citra rata-rata tersebut dipresentasikan kedalam sebuah matriks seperti dibawah ini:

$$\mu = \begin{pmatrix} \mu_1 \\ \mu_2 \\ \vdots \\ \mu_n \end{pmatrix} \quad (3)$$

Setelah didapat matriks rata-rata dapat dicari nilai *zero mean* dengan rumus:

$$\Phi_i = \mu - \Gamma_i \quad (4)$$

3. Mencari *covariance* matriks *Covariance*

matriks PCA dicari dengan mengalikan Φ dengan *transposenya*. Hasilnya adalah matriks yang sebelumnya berdimensi $N \times m$ dimana jika kita melanjutkan dari contoh sebelumnya akan menjadi matriks dengan dimensi $m \times n$.

Persamaan (1.5) menunjukkan rumus untuk mencari matriks kovarian.

$$C = (\Phi_i - \Phi_i^t) \quad (5)$$

Feature Statistik Orde Satu

1. Mean

Mean adalah perhitungan paling dasar dari seluruh perhitungan statistik. Perhitungan *mean* sendiri dapat digunakan untuk *noise reduction*. *Mean* menunjukkan ukuran dispersi dari suatu citra [11].

$$x = \sum_n F_n * p(F_n) \quad (6)$$

dimana F_n merupakan nilai intensitas citra, $P(F_n)$ merupakan nilai probabilitas kemunculan intensitas pada citra.

2. Variance (σ^2)

Variance merupakan variasi elemen-elemen matriks *konkurensi* pada histogram suatu citra. Citra dengan derajat keabuan kecil akan memiliki variansi yang kecil juga [11].

$$\sigma^2 = \sum_n (f_n - \mu)^2 p(F_n) \quad (7)$$

Dimana F_n merupakan nilai intensitas citra, $p(F_n)$ merupakan nilai histogram, μ merupakan nilai mean.

3. Skewness (α_3)

Skewness merupakan parameter yang menunjukkan tingkat kemiringan relatif kurva histogram. *Skewness* juga merupakan ketidaksimetrisan suatu data [11].

$$\alpha_3 = \frac{1}{\sigma^3} \sum_{N=0}^N (fn - \mu)^3 p(Fn) \quad (8)$$

Dimana α_3 merupakan standar deviasi dari nilai intensitas citra, F_n merupakan nilai intensitas citra, μ merupakan nilai *mean*, $p(fn)$ merupakan nilai histogram.

4. Kurtosis (α_4)

Kurtosis menunjukkan tingkat keruncingan relatif dari *probabilitas* distribusi dari nilai *real* suatu variabel acak suatu citra [11].

$$\alpha_4 = \frac{1}{\sigma^4} \sum_{N=0}^N (fn - \mu)^4 p(Fn) - 3 \quad (9)$$

Dimana α_4 merupakan standar deviasi dari nilai intensitas citra, F_n merupakan nilai intensitas citra, μ merupakan nilai *mean*, $p(fn)$ merupakan nilai histogram.

5. Entropy (H)

Menunjukkan ukuran ketidakteraturan bentuk dari suatu citra, Suatu citra bernilai kecil jika struktur citra tidak teratur (bervariasi) [11]

$$H = - \sum_n p(Fn)^2 \cdot \log p(Fn) \quad (10)$$

Dimana $p(fn)$ merupakan nilai histogram.


6. Standar Deviasi

Standar deviasi adalah rata-rata jarak dari mean ke titik data. Standar deviasi digunakan untuk mengetahui seberapa tersebar nilai data-data tersebut. Hal tersebut ditunjukkan oleh rumusan dari standar deviasi berikut [11].

$$\sigma = \sqrt{\sum n (fn - \mu)^2 p(Fn)} \quad (11)$$

2.3 Support Vector Machine (SVM)


Konsep klasifikasi SVM dapat dijelaskan secara sederhana sebagai usaha untuk mencari hyperplane terbaik yang berfungsi sebagai pemisah dua buah kelas data pada ruang input. Ide dasar dari SVM adalah memaksimalkan batas hyperplane (maximal margin hyperplane), seperti yang diilustrasikan pada Gambar 4 Pada Gambar 4 (a) ada sejumlah pilihan hyperplane yang mungkin untuk set data, dan 4 (b) merupakan hyperplane dengan margin paling maksimal. Meskipun sebenarnya juga bisa menggunakan hyperplane sembarang, hyperplane dengan margin maksimal akan memberikan hasil generalisasi yang lebih baik pada metode klasifikasi [12].



Gambar 4 Decision Boundary [12]

2.3.1 Support Vector Machine (SVM) NonLinear

SVM sebenarnya adalah *hyperplane* yang hanya bekerja pada data yang dipisahkan secara linear. Untuk data yang distribusi kelasnya tidak linear biasanya menggunakan pendekatan kernel pada fitur data awal set data [20]. Kernel dapat didefinisikan sebagai suatu fungsi yang memetakan fitur data dari dimensi awal (rendah) ke fitur baru dengan dimensi yang relatif lebih tinggi [7]



Gambar 5 Ilustrasi Kernel Untuk Memetakan Dimensi Data Dari Yang Rendah Hingga Yang Tinggi [7].

Berikut beberapa pilihan fungsi kernel yang banyak digunakan dalam aplikasi

1. Linear : $K(x, y) = x \cdot y$
2. Polynomial : $K(x, y) = (x \cdot y + c)^d$
3. Gaussian RBF : $K(x, y) = \exp\left(\frac{-\|x-y\|^2}{2\sigma^2}\right) x \cdot y$

Dimana x dan y adalah pasangan dua data dari semua bagian data latih. Parameter $\sigma, c, d > 0$, merupakan konstanta. $\|x-y\|^2$ merupakan kuadrat jarak antara vektor x dan y . Fungsi kernel mana yang harus digunakan untuk substitusi dot-product dari fitur dimensi lama ke dimensi baru sangat bergantung pada kondisi data.


2.3.2 Support Vector Machine (SVM) Multiclass

Algoritma SVM yang bersifat *binary classification* sangat handal dalam klasifikasi antar dua kelas, namun tidak mendukung untuk klasifikasi dua kelas lebih. Oleh karenanya, dibutuhkan pendekatan lain agar bisa melakukan klasifikasi. Ada 3 pendekatan SVM Multikelas yang dibahas di subbab ini, yaitu *one-against-all*, *one-against-one*, dan *error correcting output code* [3].

Pendekatan *one-against-all* (OAA) menjadikan salah satu kelas sebagai parameter benar dan menjadikan kelas lain sebagai parameter salah. Sementara pendekatan *one-against-one* (OAO) membentuk klasifikator biner sebanyak $K(K-1)/2$, dan dibuat kasifikator yang memasangkan antar dua kelas. Pada kedua pendekatan tersebut, vektor uji diklasifikasi dengan mengkombinasikan hasil dari semua klasifikator biner, biasanya menggunakan voting dari hasil semua prediksi klasifikator biner. Ketika kelas menerima voting paling banyak, maka label kelas tersebut akan diberikan kepada vektor uji tersebut [3].

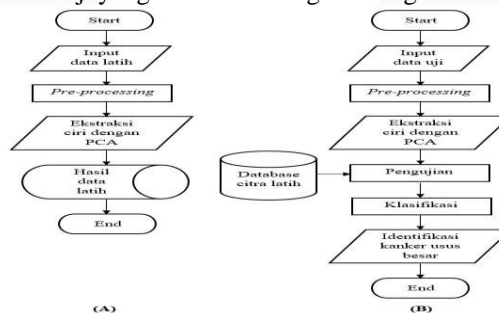
2.4 Perancangan Sistem

Secara umum, sistem yang dirancang adalah sistem yang dapat mengklasifikasikan citra kanker usus besar menjadi jenis kanker *Carcinoma*, *Lymphoma*, dan normal. perancangan ini menjelaskan langkah-langkah yang digunakan dalam pembuatan sistem deteksi kanker usus besar dengan menggunakan citra digital yang telah diakuisisi. Mulai dari proses *Preprocessing*, ekstraksi ciri menggunakan *Principal Component Analysis* (PCA) serta klasifikasi menggunakan *Support Vector Machine* (SVM), dan akan diambil nilai akurasi dari hasil pengklasifikasiannya.



Gambar 6 Diagram Blok Perancangan Sistem

Sistem ini terdiri dari dua proses utama, yaitu proses latih dan uji. Pada proses latih dilakukan pelatihan data dan selanjutnya dilakukan proses ekstraksi ciri dengan *Principal component Analysis* (PCA). klasifikasi kanker usus besar menggunakan metode klasifikasi *Support Vector Machine* (SVM). Setelah proses klasifikasi selesai adalah proses pengambilan citra uji yang akan dibandingkan dengan citra latih.



Gambar 7 Diagram Blok Model Sistem

3. Pembahasan

Pengujian sistem dilakukan untuk mengklasifikasikan citra dari penyakit kanker usus besar berdasarkan jenisnya, diantaranya *carcinoma*, *lymphoma*, dan normal. Untuk menganalisis sistem dapat dilihat dari nilai akurasi & waktu komputasi. Data kanker usus besar diambil dari RSUP Hasan Sadikin Bandung dengan total data sebanyak 192 dengan rincian 66 sampel untuk masing-masing kelas. Dengan menggunakan enam skenario pengujian. Hasil dari pengujian skenario terbaik akan digunakan sebagai acuan untuk pengujian skenario berikutnya.

3.1 Pengujian Skenario Pembagian Data Latih

Pengujian skenario pertama merupakan pengujian performansi dengan menerapkan perbandingan komposisi data latih dan data uji yang memiliki ukuran citra 64x64 piksel, ruang warna *green* (RGB), dengan variansi parameter yang terpadat pada *Principal Component Analysis* (PCA) yaitu berupa *Mean*, *Variance*, *Standard Deviation*, *Skewness*, *Kurtosis*, *Entropy*. Pada klasifikasi menggunakan metode *Support Vector Machine* (SVM) menggunakan kernel *Radial Basis Function* (RBF) dan Pembagian kelas dengan *one-against-all*. Dapat dilihat pada Tabel 1 hasil perbandingan jumlah data latih dan data uji.

Tabel 1 Pengujian perbandingan jumlah data latih dan data uji

Data	Akurasi (%)	Waktu Komputasi (Detik)
99 : 99	35,3535	19,0485
141 : 58	32,7586	11,8985
108 : 90	38,8889	15,6428

Pada skenario pertama menunjukkan bahwa pembagian data latih dan data uji berpengaruh terhadap sistem klasifikasi data kanker usus besar yang berjumlah 198 data. Berdasarkan tabel diatas komposisi 108 : 90 dengan pembagian data latih 33 dan 30 data uji memiliki nilai terbaik diantara komposisi lainnya. Hal ini menunjukkan data latih sudah cukup untuk melatih data uji, sehingga pola yang terjadi tidak terlalu ketat.

3.2 Pengujian Skenario Perubahan *Resize*

Pengujian skenario kedua merupakan kelanjutan dari skenario pertama dimana data yang digunakan adalah 108 : 90 . perubahan yang terjadi pada skenario ini adalah melakukan *Resize* citra menjadi 64x64, 100x100, 128x128, dan 256x256. Dapat dilihat pada Tabel 2 hasil pengujian *resize* terhadap performansi sistem.

Tabel 2 Pengujian Pengaruh terhadap *resize*

Size	Akurasi (%)	Waktu Komputasi (Detik)
64x64	45,5556	8,8446
100x100	42,2222	7,4963
128x128	40	6,8778
256x256	42,2222	7,5061

Tabel 2 menunjukkan bahwa *resize* pada tahap *pre-processing* mempengaruhi nilai akurasi, nilai akurasi paling tinggi pada skenario ini adalah ukuran 64x64 piksel dengan akurasi yang diperoleh adalah 45,5556. Hal ini dipengaruhi karena semakin besar *resize* pada citra kanker usus besar akan semakin mengurangi komponen ciri data tersebut.

3.3 Pengujian Skenario *Konversi Citra*

Pengujian ini dilakukan dengan menggunakan data 108 ciri latih dan 90 ciri uji dengan ukuran 64x64 piksel. Citra dikonversi dari citra RGB menjadi masing-masing layer (*Red*, *Green*, dan *blue*). Dengan variansi parameter yang terpadat pada *Principal Component Analysis* (PCA) yaitu berupa *Mean*, *Variance*, *Standard Deviation*, *Skewness*, *Kurtosis*, *Entropy*. Pada klasifikasi menggunakan metode *Support Vector Machine* (SVM) menggunakan kernel *Radial Basis Function* (RBF) dan Pembagian kelas dengan *one-against-all*. Dapat dilihat pada Tabel 3 hasil pengujian terhadap *layer* citra

Tabel 3 Pengujian terhadap *layer* citra

Konversi citra	Akurasi (%)	Waktu Komputasi (Detik)
<i>Red</i>	45,5556	8,1938
<i>Green</i>	45,5556	7,4963
<i>Blue</i>	43,3333	7,8915

Tabel 3 menunjukkan adanya pengaruh dari konversi citra pada proses *pre-processing* terhadap performansi sistem. Konversi warna *red* dan *green* menunjukkan nilai akurasi yang sama, tetapi menunjukkan waktu komputasi yang berbeda, sehingga pada skenario ini diambil konversi warna *green*.

3.4 Pengujian Skenario Parameter Statistik

Tahap ini dilakukan pengujian parameter pada sistem untuk memperoleh nilai akurasi dan waktu komputasi pada ekstraksi ciri *Principal Component Analysis*. Ciri statistik yang digunakan adalah *Mean, Variance, Standard Deviation, Skewness, Kurtosis, Entropy*. Ciri yang memiliki nilai akurasi terbaik akan menjadi acuan untuk pengujian selanjutnya. Pada pengujian ini masih menggunakan data 108 ciri latih dan 90 ciri uji dengan ukuran 64×64 piksel. Citra dikonversi dari citra RGB menjadi masing-masing layer (*Red, Green, dan blue*). Pada klasifikasi menggunakan metode *Support Vector Machine (SVM)* menggunakan kernel *Radial Basis Function (RBF)* dan Pembagian kelas dengan *one-against-all*. Dapat dilihat pada Tabel 4 hasil pengujian terhadap parameter statistik

Tabel 4 Pengujian dengan parameter statistik

Ciri statistik	Akurasi (%)	Waktu Komputasi (Detik)
<i>Entropy</i>	53,333	7,442
<i>Mean, Entropy</i>	58,427	6,8384
<i>Entropy, Mean, Skewness</i>	72,2222	6,4492
<i>Mean, Standard Deviation, Skewness, Entropy</i>	65,5556	6,6766
<i>Mean, Standard Deviation, Skewness, Variance, Entropy</i>	69,8925	4,0863
<i>ENTROPY,MEAN, SKEWNESS,STANDARD DEVIATION,VARIANCE, KURTOSIS</i>	65,5556	6,4402

Berdasarkan Tabel 4 menunjukkan bahwa nilai akurasi tertinggi didapatkan dengan menggunakan parameter *Entropy, Mean, dan Skewness* memiliki nilai akurasi sebesar 72,2222% dan waktu komputasi selama 6,4492 detik. kombinasi tiga parameter yaitu *entropy, mean, dan skewness* paling dapat mewakili ciri masing-masing citra uji.

3.5 Pengujian Skenario Perubahan Kernel Pada (SVM)

Pada Skenario kelima dilakukan dengan menggunakan 90 data uji memiliki ukuran 64×64 piksel, citra warna *green*, memakai parameter *Entropy, Mean, dan Skewness*. Pada proses klasifikasi metode *Support Vector Machine (SVM)* dilakukan kernel *Radial Basis Function (RBF), Linear, dan Gaussian* dan Pembagian kelas dengan *one-against-all, one-against-one*. Dapat dilihat pada Tabel 5 hasil pengujian *kernel function*.

Tabel 5 Pengujian Perubahan Kernel

Kernel	Akurasi (%)	Waktu Komputasi (Detik)
<i>RBF</i>	72,2222	6,4553
<i>Linear</i>	58,8889	5,9812
<i>Gaussian</i>	72,2222	6,7363

Pada tabel 5 menunjukkan hasil pengujian yang dilakukan dengan perubahan *kernel function* pada klasifikasi *Support Vector Machine (SVM)*. Berdasarkan grafik diatas dapat diketahui nilai akurasi antara *RBF* dan *gaussian* memiliki persamaan, tetapi waktu komputasi paling cepat adalah menggunakan *kernel Radial Basis Function (RBF)*.

3.6 Pengujian Skenario Perubahan Parameter SVM Multiclass

Pada skenario keenam ini dengan menggunakan 90 data uji memiliki ukuran 64×64 piksel, citra warna *green*, memakai parameter *Entropy, Mean, dan Skewness*. Pada proses klasifikasi metode *Support Vector Machine (SVM)* dilakukan kernel *Radial Basis Function (RBF)*, dan Pembagian kelas dengan *one-against-all, one-against-one*. Dapat dilihat pada Tabel 6 hasil pengujian perubahan parameter *svm multiclass*

Tabel 6 Pengujian Perubann parameter SVM multiclass

	Akurasi (%)	Waktu Komputasi (Detik)
<i>Onevsall</i>	72,2222	7,3046
<i>Onevsone</i>	74,4444	6,4654

Pada tabel 6 Menunjukkan adanya pengaruh dari salah satu parameter *Support Vector Machine (SVM) multiclass*. Akurasi tertinggi didapat ketika *one-against-one* dipilih menjadi parameter (SVM) *multiclass*.

4. Kesimpulan

Perancangan sistem klasifikasi dengan metode ekstraksi ciri *Principal Component Analysis* (PCA) dan klasifikasi *Support Vector Machine* (SVM) berhasil dilakukan untuk mengenali kanker usus besar yang terdiri dari *carcinoma*, *lymphoma*. Serta usus Normal. Dengan akurasi tertinggi sebesar 74,44% dengan waktu komputasi rata-rata 6,465487 detik. Performansi terbaik sistem didapatkan dengan menggunakan *resize* 64 ×64 *piksel* dengan *Layer green*. Serta Penambahan parameter pada ekstraksi ciri yaitu *entropy*, *mean*, dan *skewness* secara bersamaan, dan dengan memakai *kernel Radian Basis Function* serta pembagian *multiclass one-against-one* pada klasifikasi *Support Vector Machine*.

Daftar Pustaka

- [1] Y. D. Kurniawan, *Klasifikasi Kanker Usus Besar Menggunakan Ekstraksi Ciri Grey Level Co-occurrence Matrix dengan Metode Levenberg-Marquardt Algorithm*. Bandung : Universitas Telkom. 2013
- [2] A. R. Putra, *Klasifikasi Kanker Usus Besar Berbasis Pengolahan Citra Digital dengan Metode Radial Basis Function (RBF) 1*, no. x. Bandung: Institut Teknologi Telkom, 2012.
- [3] A. Zardi, *Klasifikasi Kanker Usus Besar Berdasarkan Analisis Tekstur Dengan Deteksi Binary Large Object (BLOB)*. Bandung: Universitas Telkom, 2015.
- [4] W. Desen and Zhizhong, Kanker Usus Besar [Online]. Available: <http://www.asiancancer.com/indonesian/cancer-topics/colon-cancer/>. [Accessed: 13 September 2016]
- [5] E. Kramarova and C. Stiller, The international classification of childhood cancer. *Int J Cancer*, 1996.
- [6] Jane Reece, L. A. Urry, N. Meyers, M. L. Cain, S. A. Wasserman, P. V. Minorsky, R. B. Jackson, and B. N. Cooke, *Campbell Biology: 10th*. San Francisco, CA: Pearson Benjamin Cummings. 2015
- [7] Z. A. Trimarsih, *Klasifikasi Kanker Usus berdasarkan Citra Mikroskopik Patologi Menggunakan Contourlet Transform dan Support Vector Machine (SVM)*, Bandung : Institut Teknologi Telkom, 2013
- [8] R. O. Tiaramukti, *Klasifikasi Kanker Usus Besar Menggunakan Ekstraksi Ciri Principal Analysis Component dengan Metode K-Nearest Neighbor Berbasis Pengolahan*. Bandung: Universitas Telkom. 2018
- [9] M. H. Purnomo and A. Muntasa, *Konsep pengolahan citra digital dan ekstrasi fitur*. Yogyakarta: Graha Ilmu, 2010.
- [10] K. Mujib, A. Hidayatno dan T. Prakoso, "Pengenalan Wajah Menggunakan Local Binary Pattern (LBP) Dan Support Vector Machine (SVM)," *TRANSIENT*, vol. 7, no. 1, pp. 124-130, 2018.
- [11] V. Kumar, P.Gupta. *Importance of Statistication Measure In Digital Image Processing*. IJETAE. Vol.2. 2012.
- [12] Y. Cathy, "Support Vector Machines for classification," [Online]. Available: <http://efavdb.com/svmclassification/>. [Diakses 14 Mei 2017].
- [13] F. Masitha, *Deteksi Kanker Kolorektal (Kanker Usus Besar) Menggunakan Metode Gray Level Cooccurrence Matrix dan K-Nearest Neighbor Berbasis Pengolahan*. Bandung: Universitas Telkom. 2017
- [14] N. V. Lima, L. Novamizanti, E. Susatio, Sistem Pengenalan Wajah 3D Menggunakan ICP dan SVM, *Jurnal Teknologi Informasi dan Ilmu Komputer (TJIJK)*, Vol. 6, No. 6, 2019.