

SUPPORT VECTOR MACHINE UNTUK DETEKSI ANEMIA SECARA NON-INVASIF MELALUI KONJUNGTIVA MATA BERBASIS PENGOLAHAN CITRA DIGITAL

SUPPORT VECTOR MACHINE FOR NON-INVASIVE ANEMIA DETECTION THROUGH CONJUNCTIVA ON EYES BASED ON DIGITAL IMAGE PROCESSING

Rizki Muhammad Iqbal¹, Ir. Rita Magdalena, M.T.², R Yunendah Nur Fu'adah, S.T., M.T.³

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

¹rzkmhmd@student.telkomuniversity.ac.id, ²ritamagdalenat@telkomuniversity.ac.id, ³yunendah@telkomuniversity.ac.id

Abstrak

Anemia dapat dideteksi melalui darah dengan menggunakan alat Hemoglobin meter (Hb meter) yang bersifat invasif karena sampel darah didapatkan melalui penusukan menggunakan jarum. Selain itu, anemia dapat dideteksi menggunakan metode alternatif yang bersifat non-invasif dengan mengamati kondisi klinis yang dapat dilihat berdasarkan keputihan pada konjungtiva mata, lidah, telapak tangan, dan kuku.

Tugas akhir ini mendeteksi anemia berdasarkan keputihan pada konjungtiva mata sebagai metode non-invasif melalui citra digital menggunakan Support Vector Machine (SVM) dan menggunakan citra Red, Green, dan Blue (RGB), citra Hue, Saturation, dan Value (HSV), dan citra Grayscale dengan format *.png, serta mengambil nilai parameter mean, variance, skewness, kurtosis, dan entropy sebagai ekstraksi ciri. Klasifikasi citra yang digunakan adalah metode Support Vector Machine (SVM) menggunakan aplikasi MATLAB.

Dalam upaya mencapai akurasi terbaik, variabel pengujian yang diteliti menggunakan variabel kombinasi antara parameter dan kernel SVM (kernel RBF, linear, dan polynomial). Secara keseluruhan dengan menggunakan metode klasifikasi SVM pada deteksi anemia, berhasil diperoleh akurasi tertinggi sebesar 72.9167% menggunakan kernel RBF dengan waktu komputasi 0.762 detik dan jumlah data latih 35 buah dan data uji 48 buah.

Kata Kunci : HSV, Konjungtiva mata, RGB, Support Vector Machine

Abstract

Anemia can be detected through blood by using a Hemoglobin meter (Hb meter) which is invasive because the blood sample is obtained by needle pricked. It also can be detected by an alternative non-invasive method that observe the clinical conditions, can be seen from the paleness of eye conjunctiva, tongue, palms, and nails.

This final project use the pallor of the eye conjunctiva as a non-invasive method through digital images using Support Vector Machine (SVM) to detect anemia, and used Red, Green, and Blue (RGB) layers, Hue, Saturation, and Value (HSV) layers, and Grayscale layers with *.png format are used in this project. Mean, variance, skewness, kurtosis, and entropy parameters are used as an extraction features. For image classification, this final project use Support Vector Machine (SVM) method with MATLAB application.

In order to achieve the best accuracy, the variables are used in this project are the combination of parameter and SVM kernels (RBF, linear, and polynomial kernels). Overall, the highest accuracy was 72.9167% using the RBF kernel with a computation time 0.762 seconds and using 35 training data and 48 test data.

Keywords : Eye Conjunctiva, HSV, RGB, Support Vector Machine

1. PENDAHULUAN

1.1 Latar Belakang

Anemia dapat dideteksi dengan metode *complete blood cell, peripheral smear, reticulocyte count*, dan *serum iron indices* [6]. Metode tersebut bersifat invasif karena membutuhkan darah sebagai sampel untuk deteksi anemia. Terdapat cara lain untuk mendeteksi anemia yaitu dengan mengamati kondisi klinis yang dapat dilihat dari keputihan pada konjungtiva mata, lidah, telapak tangan, dan kuku. Anemia dapat diidentifikasi melalui keputihan pada konjungtiva mata sehingga dapat dimanfaatkan sebagai salah satu metode deteksi anemia,

Pada tugas akhir ini, untuk dapat membantu deteksi anemia digunakan *Digital Image Processing*. Hal ini dilakukan dengan metode ekstraksi ciri dengan mengambil nilai parameter ciri orde pertama pada *layer* citra *Red Green Blue* (RGB), citra *Hue Saturation Value* (HSV), dan citra *grayscale*. Citra RGB konjungtiva mata diambil melalui kamera *smartphone*, lalu dilakukan ekstraksi ciri dengan mengambil nilai *mean, variance, skewness, kurtosis*, dan *entropy* pada citra RGB, citra HSV, dan citra *grayscale*. Citra hasil ekstraksi ciri diklasifikasi menggunakan metode SVM.

2. DASAR TEORI

2.1 Anemia

Anemia (berasal dari Bahasa Yunani, anai-mia yang memiliki arti kekurangan darah) didefinisikan sebagai penurunan jumlah total hemoglobin atau jumlah *red blood cell* (RBC) dalam darah [6]. Anemia dapat menyebabkan gejala sesak napas, kelelahan, jantung berdebar, kulit kering dan kasar, vertigo, pucat, dan disfungsi neurokognitif [9].

2.2 Konjungtiva

Konjungtiva adalah membran mukosa tipis dan transparan yang melapisi permukaan posterior kelopak mata (*palpebral conjunctiva*) dan permukaan anterior sklera (*bulbar conjunctiva*). Di tepi superior dan inferior tarsus, konjungtiva melipat ke posterior (pada fornix superior dan inferior) dan membungkus jaringan episklera menjadi konjungtiva bulbaris. Konjungtiva bulbaris melekat longgar ke septum orbital di fornix dan melipat berkali-kali. Adanya lipatan-lipatan ini memungkinkan bola mata bergerak dan memperbesar permukaan konjungtiva sekretorik.

2.3 Ekstraksi Ciri

Ekstraksi ciri merupakan proses pengambilan ciri atau parameter dari sebuah citra. Ekstraksi ciri orde pertama merupakan metode pengambilan ciri yang didasarkan pada karakteristik histogram citra. Histogram menunjukkan probabilitas kemunculan nilai derajat keabuan piksel pada suatu citra. Dari nilai-nilai pada histogram yang dihasilkan, dapat dihitung beberapa parameter ciri orde pertama yaitu *mean, variance, skewness, kurtosis, entropy* [18].

2.3.1 Mean (μ)

Menunjukkan ukuran disperse dari suatu citra [18].

$$\mu = \sum_n f_n p(f_n) \quad (2.1)$$

Dimana f_n merupakan suatu nilai intensitas keabuan, dan $p(f_n)$ menunjukkan nilai histogramnya (probabilitas kemunculan intensitas tersebut pada citra).

2.3.2 Variance (σ^2)

Menunjukkan variansi elemen pada histogram dari suatu citra [18].

$$\sigma^2 = \sum_n (f_n - \mu)^2 p(f_n) \quad (2.2)$$

2.3.3 Skewness (α_3)

Menunjukkan tingkat kemencengan relatif kurva histogram dari suatu citra [18].

$$\alpha_3 = \frac{1}{\sigma^3} \sum_n (f_n - \mu)^3 p(f_n) \quad (2.3)$$

2.3.4 Kurtosis (α_4)

Menunjukkan tingkat keruncingan relative kurva histogram dari suatu citra [18].

$$\alpha_4 = \frac{1}{\sigma^4} \sum_n (f_n - \mu)^4 p(f_n) - 3 \quad (2.4)$$

2.3.5 Entropy (H)

Menunjukkan ukuran ketidakaturan bentuk dari suatu citra [18].

$$H = -\sum_n p(f_n) \cdot \log_2 p(f_n) \quad (2.5)$$

2.4 Support Vector Machine (SVM)

Support Vector Machine (SVM) yaitu metode yang memiliki prinsip *linear classifier learning machine* yang bekerja atas prinsip *Structural Risk Minimization* (SRM) dengan tujuan menemukan *hyperplane* terbaik yang memisahkan dua buah kelas pada *input space*. SVM tidak hanya dapat menyelesaikan masalah linear namun dapat digunakan pada non-linier dengan menggunakan *kernel trick* pada ruang kerja berdimensi tinggi.

2.4.1 Linearly Separable Data

Linearly separable data adalah data yang dapat dipisah secara linier, klasifikasi dilakukan dengan mencari *hyperplane* untuk memisahkan dua buah kelas pada *input space* [19].

Data yang tersedia dinotasikan sebagai $\vec{x}_i \in \mathcal{R}^d$ sedangkan pada label masing-masing dinotasikan sebagai $y_i \in \{-1, +1\}$ untuk seluruh i sebanyak n dan didefinisikan dengan rumus [19] :

$$\vec{w} \cdot \vec{x}_i + b = 0 \quad (2.6)$$

Pattern \vec{x}_i yang termasuk dalam kelas - 1 dirumuskan sebagai pertidaksamaan [19] :

$$\vec{w} \cdot \vec{x}_i + b \leq -1 \quad (2.7)$$

Sedangkan *Pattern* \vec{x}_i yang termasuk dalam kelas +1 dirumuskan dengan pertidaksamaan [19]:

$$\vec{w} \cdot \vec{x}_i + b \geq +1 \quad (2.8)$$

Margin terbesar dapat ditemukan dengan memaksimalkan nilai jarak antara *hyperplane* dan titik terdekatnya, yaitu $1/\|\vec{w}\|$, dirumuskan sebagai *Quadratic Programming* (QP) *problem*, yaitu mencari titik minimal persamaan (2.9) dengan memperhatikan constraint persamaan (2.10), sehingga [19] :

$$\min_{\vec{w}} \tau(\vec{w}) = \frac{1}{2} \|\vec{w}\|^2 \quad (2.9)$$

$$y_i(\vec{x}_i \cdot \vec{w} + b) - 1 \geq 0, \forall i \tag{2.10}$$

Masalah ini dapat diselesaikan dengan menggunakan rumus *Lagrange Multiplier* [19]:

$$L(\vec{w}, b, \alpha) = \frac{1}{2} \|\vec{w}\|^2 - \sum_{i=1}^n \alpha_i (y_i (\vec{x}_i \cdot \vec{w} + b) - 1) \tag{2.11}$$

α_i adalah *lagrange multipliers* yang bernilai nol atau positif ($\alpha_i \geq 0$). Nilai optimal persamaan (2.11) dapat dihitung dengan meminimalkan L terhadap \vec{w} dan b , dan memaksimalkan L terhadap α_i . Sifat titik optimal gradien $L=0$, persamaan (2.11) dapat dimodifikasi sebagai maksimalisasi masalah yang hanya mengandung α_i , seperti persamaan [19]:

$$\text{Maximize : } \sum_{i=1}^n \alpha_i \alpha_j y_i y_j \vec{x}_i \cdot \vec{x}_j \tag{2.12}$$

$$\text{Subjek : } \alpha_i \geq 0 \ (i = 1, 2 \dots, n) \ \sum_{i=1}^n \alpha_i y_i = 0 \tag{2.13}$$

Dari hasil perhitungan tersebut diperoleh kebanyakan α_i bernilai positif, data yang berkorelasi dengan α_i positif disebut sebagai *support vector*.

Dalam realisasinya, kedua kelas pada *input space* tidak dapat terpisah secara sempurna dan menyebabkan constraint pada persamaan (2.9) tidak dapat dipenuhi, sehingga optimisasi tidak dapat dilakukan. Oleh karena itu, dibutuhkan teknik *softmargin* yang memodifikasi persamaan (2.18) dengan memasukkan *slack variable* ξ_i ($\xi_i > 0$) sebagai berikut [19] :

$$y_i(\vec{x}_i \cdot \vec{w} + b) \geq 1 - \xi_i, \forall i \tag{2.14}$$

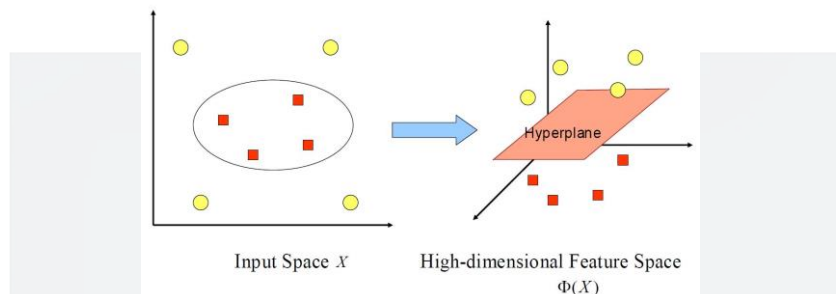
Dengan demikian persamaan persamaan (2.17) diubah menjadi [19] :

$$\min_{\vec{w}} \tau(\vec{w}, \xi) = \frac{1}{2} \|\vec{w}\|^2 + C \sum_{i=1}^n \xi_i \tag{2.15}$$

Parameter C dipilih untuk mengontrol *tradeoff* antara margin dan *error* klasifikasi ξ . Semakin besar nilai C , maka akan memberi penalti yang makin besar pula terhadap *error* klasifikasi.

2.4.2 Non Linearly Separable Data

Jika data yang digunakan pada klasifikasi SVM bersifat *non-linear separable*, maka dibutuhkan fungsi *kernel* untuk mendapatkan hasil yang baik berprinsip data \vec{x} dipetakan oleh fungsi $\Phi(x)$ ke ruang vektor yang dimensinya lebih tinggi. Pada ruang vektor baru, *hyperplane* pemisah akan dikonstruksikan [19].



Gambar 2.7 Hyperplane non-linear separable data.

Pemetaan dilakukan untuk menjaga topologi data, jika ada dua data bergerak dekat pada *input space*, maka akan berjarak dekat juga pada *feature space* dan berlaku sebaliknya. Proses pembelajaran SVM dalam menemukan titik-titik *support vector* bergantung pada *dot product* dari data yang sudah ditransformasikan pada ruang baru yang berdimensi lebih tinggi yaitu :

Untuk mempermudah perhitungan maka *dot product* digantikan dengan fungsi kernel atau yang sering disebut *kernel trick*, berikut adalah rumus *kernel trick* [19] :

$$K(\vec{x}_i, \vec{x}_j) = \Phi(\vec{x}_i) \cdot \Phi(\vec{x}_j) \tag{2.16}$$

Dari hasil klasifikasi dari data \vec{x} diperoleh persamaan [19] :

$$f(\Phi(\vec{x})) = \vec{w} \cdot \Phi(\vec{x}) + b \tag{2.17}$$

$$= \sum_{i=1, x_i \in SV}^n \alpha_i y_i \Phi(x) \cdot \Phi(\vec{x}_i) + b \tag{2.18}$$

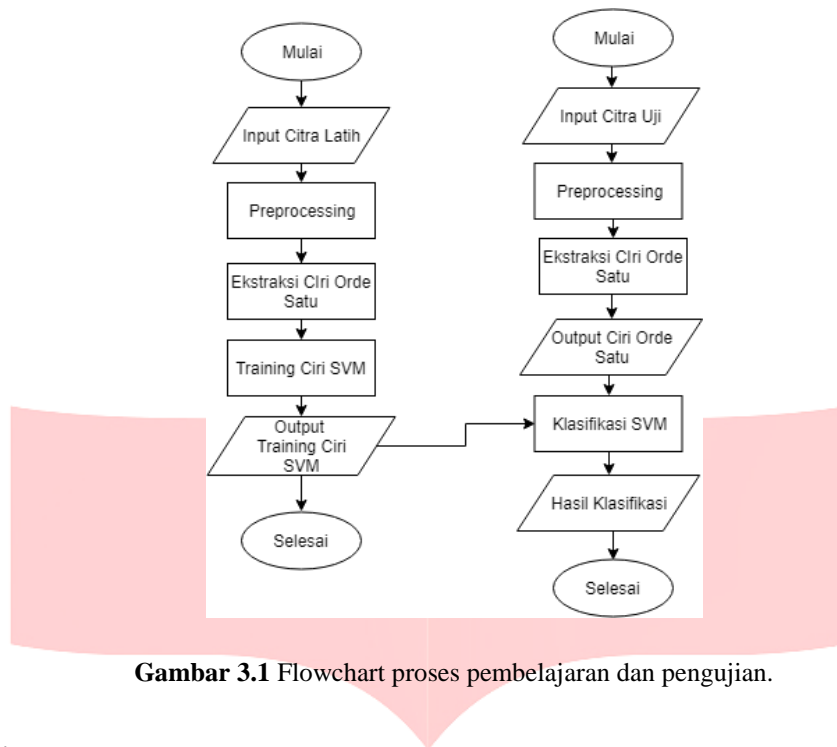
$$= \sum_{i=1, x_i \in SV}^n \alpha_i y_i K(x, \vec{x}_i) + b \tag{2.19}$$

SV pada persamaan dimaksudkan dengan subset dari *training set* yang terpilih sebagai *support vector* atau dengan kata lain data \vec{x}_i yang berkorespondensi pada $\alpha_i \geq 0$.

3. Pembahasan

3.1 Flowchart Sistem

Perancangan sistem yang dibuat adalah untuk mendeteksi penyakit anemia dengan menggunakan citra konjungtiva mata. Sistem deteksi anemia ini dirancang dalam dua bagian utama yaitu, proses pembelajaran dan proses pengujian. Berikut sistem deteksi anemia pada proses pembelajaran untuk memperoleh database citra latih dan citra uji :




Gambar 3.1 Flowchart proses pembelajaran dan pengujian.

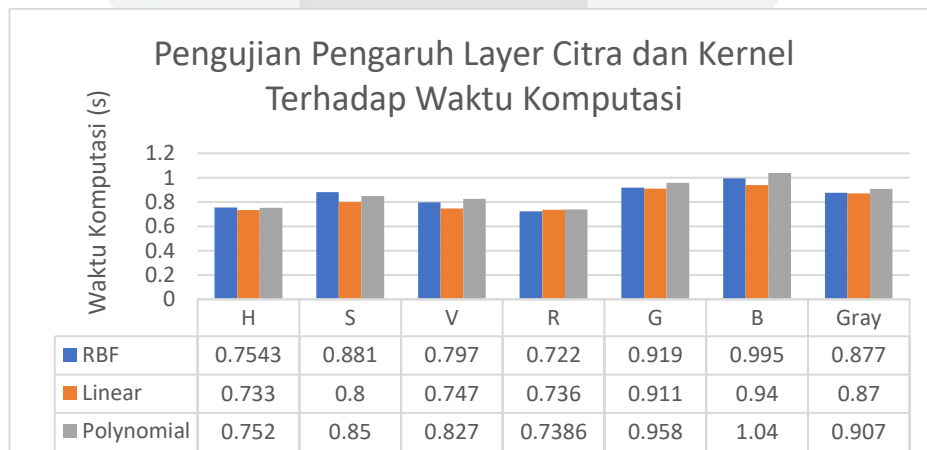
3.2 Hasil Pengujian

3.2.1 Analisis Pengaruh Layer Citra terhadap Akurasi dan Waktu Komputasi

Pada bagian ini akan dilakukan pengujian terhadap 48 citra mata dengan membandingkan layer *R, G, B, H, S, V, dan Grayscale* menggunakan ciri orde pertama *mean, variance, skewness, kurtosis* dan *entropy*. Berikut adalah grafik pengujian pengaruh layer citra dan kernel terhadap akurasi sistem dan waktu komputasi :



Gambar 3.2 Grafik pengujian pengaruh layer citra dan kernel terhadap akurasi sistem.



Gambar 3.3 Grafik pengujian pengaruh layer citra dan kernel terhadap waktu komputasi.

Berdasarkan Gambar 3.2 dapat dilihat bahwa tingkat akurasi citra tertinggi menggunakan lima parameter orde satu yaitu 70.833% menggunakan kernel linear pada layer saturation, akan tetapi kombinasi parameter bisa mempengaruhi tingkat akurasi sistem maka pengujian lima parameter tidak bisa dijadikan sebagai acuan dan dibutuhkan penelitian lebih lanjut. Oleh karena itu diambil tiga nilai akurasi tertinggi berdasarkan Gambar 3.2, didapatkan nilai akurasi tinggi pada layer hue sebesar 66.6667%, layer saturation sebesar 70.833%, dan layer green sebesar 64.583%.

3.2.2 Analisis Pengaruh Parameter SVM pada Layer Hue, Saturation, Green terhadap Akurasi dan Waktu Komputasi

3.2.2.1 Pengujian Satu Parameter

Setelah didapatkan layer dengan tiga akurasi terbaik, dilakukan analisis pengujian menggunakan satu parameter antara *mean*, *variance*, *skewness*, *kurtosis*, dan *entropy* pada layer *hue*, *saturation*, *green* terhadap akurasi dan waktu komputasi sistem. Didapatkan parameter terbaik menggunakan *skewness* dan kernel

Keterangan : *M* = Mean, *V* = Variance, *S* = Skewness, *K* = Kurtosis, *E* = Entropy

Tabel 3.1 Pengujian satu parameter.

Layer Citra	Parameter Klasifikasi	Waktu Komputasi (s)			Akurasi Sistem (%)		
		RBF	Linear	Polynomial	RBF	Linear	Polynomial
Layer H	M	0.97	0.72	2.01	66.667	39.583	68.75
	V	1.04	0.774	1.76	56.25	31.25	58.333
	S	0.833	0.79	1.67	72.91	70.83	29.1667
	K	0.749	0.734	1.8	66.66	70.83	39.583
	E	0.757	0.73	1.8	64.58	70.83	54.1667
Layer S	M	0.838	0.776	1.82	37.5	56.25	29.1667
	V	0.786	0.789	1.75	54.16	70.83	64.5833
	S	0.809	0.772	1.802	62.5	70.83	29.1667
	K	0.778	0.773	1.971	70.83	70.83	70.833
	E	0.76	0.772	1.712	58.3	66.66	66.6667
Layer G	M	0.736	0.717	1.834	54.16	70.83	64.58
	V	0.7415	0.717	1.694	56.25	70.83	47.91
	S	0.7369	0.73	1.799	66.66	70.83	37.5
	K	0.743	0.719	1.635	66.66	70.83	33.33
	E	0.923	0.72	2.48	54.16	68.75	66.66

3.2.2.2 Pengujian Dua Parameter

Analisis pengujian menggunakan dua parameter antara *mean*, *variance*, *skewness*, *kurtosis*, dan *entropy* pada layer *hue*, *saturation*, *green* terhadap akurasi dan waktu komputasi sistem.

Keterangan : *M* = Mean, *V* = Variance, *S* = Skewness, *K* = Kurtosis, *E* = Entropy

Tabel 3.2 Pengujian dua parameter.

Layer Citra	Parameter Klasifikasi	Waktu Komputasi (s)			Akurasi Sistem (%)		
		RBF	Linear	Polynomial	RBF	Linear	Polynomial
Layer H	M,V	0.78	0.73	1.41	68.75	39.583	56.25
	M,S	0.813	0.74	1.87	66.66	39.583	29.1667
	M,K	0.768	0.74	1.87	66.66	39.583	66.6667
	M,E	0.757	0.767	0.829	66.66	39.583	56.25
	V,S	0.85	0.766	1.752	64.58	29.1667	47.9167
	V,K	0.777	0.752	1.83	52.08	31.25	27.0833
	V,E	0.726	0.718	0.771	60.41	41.667	54.1667
	K,E	0.725	0.712	0.816	58.3	60.4197	58.33
	S,K	0.762	0.744	1.74	72.91	35.4167	72.91
	S,E	0.745	0.71	0.8	60.41	54.1667	52.083
	M,V	0.84	0.792	1.68	56.25	58.33	45.833
	M,S	0.795	0.751	1.232	54.1667	60.4167	47.9167
	M,K	0.748	0.74	0.815	56.25	58.33	54.1667

Layer S	M,E	0.84	0.802	1.84	54.1667	68.75	58.33
	V,S	0.8	0.785	0.894	56.25	70.83	52.083
	V,K	0.832	0.803	0.833	62.5	66.6667	37.5
	V,E	0.775	0.783	1.954	47.9167	66.6667	66.6667
	K,E	0.781	0.738	0.796	68.75	70.83	60.4167
	S,K	0.787	0.732	0.777	64.5833	50	58.33
	S,E	0.855	0.756	0.82	54.1667	68.75	45.833
Layer G	M,V	0.737	0.884	1.15	45.83	64.58	54.16
	M,S	0.982	0.969	1.098	52.08	70.83	54.16
	M,K	0.954	0.911	1.08	54.16	70.83	39.58
	M,E	0.911	0.867	2.28	72.91	68.75	62.5
	V,S	0.904	0.892	0.953	50	70.83	39.58
	V,K	0.977	0.969	0.984	47.916	70.83	54.16
	V,E	0.908	0.938	2.62	56.25	68.75	52.08
	K,E	0.933	0.915	1.134	39.58	68.75	68.75
	S,K	0.965	0.922	1.076	41.66	70.83	62.5
	S,E	0.894	0.881	1.27	47.916	68.75	43.75

3.2.2.3 Pengujian Tiga Parameter

Analisis pengujian menggunakan tiga parameter antara *mean*, *variance*, *skewness*, *kurtosis*, dan *entropy* pada layer *hue*, *saturation*, *green* terhadap akurasi dan waktu komputasi sistem.

Keterangan : *M* = Mean, *V* = Variance, *S* = Skewness, *K* = Kurtosis, *E* = Entropy

Tabel 3.3 Pengujian tiga parameter.

Layer Citra	Parameter Klasifikasi	Waktu Komputasi (s)			Akurasi Sistem (%)		
		RBF	Linear	Polynomial	RBF	Linear	Polynomial
Layer H	S,K,E	0.749	0.722	0.749	62.5	39.583	60.4167
	M,V,S	0.733	0.758	1.79	70.83	39.583	62.5
	M,V,K	0.79	0.755	1.88	70.83	39.583	56.25
	M,V,E	0.722	0.7	0.791	66.66	41.667	58.33
Layer S	S,K,E	0.823	0.791	0.81	58.33	70.833	66.667
	M,V,S	0.879	0.83	1.16	56.25	60.416	43.75
	M,V,K	0.87	0.855	0.868	56.25	62.5	54.1667
	M,V,E	0.801	0.797	0.95	54.1667	66.667	56.25
Layer G	S,K,E	0.967	0.956	0.933	47.91	68.75	66.66
	M,V,S	0.953	0.87	0.96	50	66.66	41.66
	M,V,K	0.904	0.891	0.937	43.75	66.66	37.5
	M,V,E	0.904	0.897	0.937	70.83	43.75	31.25

3.2.2.4 Pengujian Empat Parameter

Analisis pengujian menggunakan empat parameter antara *mean*, *variance*, *skewness*, *kurtosis*, dan *entropy* pada layer *hue*, *saturation*, *green* terhadap akurasi dan waktu komputasi sistem.

Keterangan : *M* = Mean, *V* = Variance, *S* = Skewness, *K* = Kurtosis, *E* = Entropy

Tabel 3.4 Pengujian satu parameter.

Layer Citra	Parameter Klasifikasi	Waktu Komputasi (s)			Akurasi Sistem (%)		
		RBF	Linear	Polynomial	RBF	Linear	Polynomial

Layer H	V,S,K,E	0.7654	0.734	0.753	60.416	39.583	47.9167
	M,V,S,K	0.797	0.759	1.85	68.75	41.667	45.8333
	M,V,S,E	0.753	0.733	0.765	64.583	41.667	52.0833
Layer S	V,S,K,E	0.81	0.75	0.77	45.833	72.916	60.4167
	M,V,S,K	0.791	0.786	1.83	60.416	58.33	56.25
	M,V,S,E	0.739	0.738	0.79	56.25	64.583	41.6667
Layer G	V,S,K,E	0.924	0.884	0.956	50	68.75	45.83
	M,V,S,E	0.914	0.908	0.944	52.083	68.75	58.33
	M,V,S,K	0.976	0.928	0.93	43.75	64.58	43.75

3.2.3 Pengujian Pengaruh Jumlah Data Uji dan Data Latih terhadap Akurasi

Penggunaan jumlah data uji dan data latih pada sistem deteksi ini tentunya akan mempengaruhi nilai akurasi dan waktu komputasi sistem. Pada pengujian ini akan digunakan parameter *skewness*, *kurtosis* dan kernel RBF pada layer citra H yang menghasilkan akurasi terbaik, lalu mengaplikasikannya terhadap beberapa jumlah data uji dan data latih. Berikut ini adalah hasil dari pengujian :

Tabel 3.4 Hasil pengujian jumlah data latih-data uji terhadap tingkat akurasi.

Jumlah Data Latih	Jumlah Data Uji	Akurasi Sistem (%)		
		Linear	RBF	Polynomial
28	55	23.6	29.09	70.9
35	48	35.4167	72.9167	72.9167
39	44	65.9	65.9	68.18
43	40	62.5	62.5	62.5
45	38	60.52	60.52	55.26
Rata-rata		49.58	58.18	65.95

4. Kesimpulan

Dari hasil analisis terhadap pengujian yang dilakukan pada sistem deteksi anemia berdasarkan citra digital menggunakan SVM, maka dapat disimpulkan sebagai berikut :

- Metode ekstraksi ciri dengan mengambil ciri orde pertama dan menggunakan klasifikasi SVM dapat dikatakan cukup baik dengan tingkat akurasi paling tinggi 72.9167% menggunakan layer *Hue*.
- Jumlah data latih dan data uji yang digunakan dalam klasifikasi menggunakan metode SVM mempengaruhi tingkat akurasi pengenalan data uji. Jumlah data latih terbaik yang mampu memberikan akurasi tertinggi pada pengenalan data uji adalah 48 buah data latih.
- Dari hasil pengujian didapatkan kombinasi parameter dan kernel yang baik dalam sistem deteksi anemia yaitu menggunakan parameter *skewness* dan *kurtosis* menggunakan kernel *RBF* atau *polynomial*.
- Parameter *skewness* terdapat pada seluruh kombinasi parameter akurasi terbaik, dapat disimpulkan *skewness* adalah parameter yang terbaik untuk deteksi anemia dibandingkan dengan parameter lainnya.
- Berdasarkan hasil pengujian, kernel linear merupakan kernel dengan waktu komputasi tercepat dibandingkan kernel RBF dan polynomial dan kernel linear cocok digunakan pada pengujian analisis tiga dan empat parameter pada layer S, sementara pada analisis satu dan dua parameter pada layer H cocok digunakan kernel RBF meskipun waktu komputasinya lebih lambat dari kernel linear.

Saran yang dapat diberikan penulis untuk perkembangan Tugas Akhir ini antar lain :

- Pengambilan akusisi citra uji dan citra latih dengan mempertahankan intensitas cahaya yang sama dapat menghasilkan akurasi yang lebih baik dari hasil akurasi pada Tugas Akhir ini.
- Penambahan proses pada tahap *preprocessing* dapat meningkatkan akurasi pengenalan citra.
- Penambahan penggunaan metode lain pada proses klasifikasi sehingga diakhir dapat dibandingkan hasilnya

Daftar Referensi

- [1] J. B. Sharma and M. Shankar, "Anemia in Pregnancy . PREVALENCE OF ANEMIA IN," *Indian J. Med. Res.*, vol. 23, no. 4, pp. 253–260, 2010.

- [2] N. Baig-Ansari *et al.*, "Anemia prevalence and risk factors in pregnant women in an urban area of Pakistan," *Food Nutr. Bull.*, vol. 29, no. 2, pp. 132–139, 2008.
- [3] H. A. Chowdhury, K. R. Ahmed, F. Jebunessa, J. Akter, S. Hossain, and M. Shahjahan, "Factors associated with maternal anaemia among pregnant women in Dhaka city," *BMC Womens. Health*, vol. 15, no. 1, pp. 1–6, 2015.
- [4] World Health Organization, "the Global Prevalence of Anaemia in 2011," *WHO Rep.*, p. 48, 2011.
- [5] N. S. Lisa Indrian Dini, Pandu Riono, "Kementerian kesehatan republik indonesia," *J. Kesehat. Reproduksi*, vol. 7, no. April, pp. 119–133, 2016.
- [6] T. D. Johnson-Wimbley and D. Y. Graham, "Diagnosis and management of iron deficiency anemia in the 21st century," *Therap. Adv. Gastroenterol.*, vol. 4, no. 3, pp. 177–184, 2011.
- [7] A. Kalantri, M. Karambelkar, R. Joshi, S. Kalantri, and U. Jajoo, "Accuracy and reliability of pallor for detecting anaemia: A hospital-based diagnostic accuracy study," *PLoS One*, vol. 5, no. 1, pp. 1–6, 2010.
- [8] A. Irum, M. U. Akram, S. Ayub, S. Waseem, and M. J. Khan, "Anemia Detection using Image Processing," pp. 31–36, 2016.
- [9] S. Aldallal, "Iron Deficiency Anaemia : A Short Review," vol. 2, no. 1, pp. 1–6, 2016.
- [10] E. McLean, M. Cogswell, I. Egli, D. Wojdyla, and B. de Benoist, "Worldwide prevalence of anaemia, WHO Vitamin and Mineral Nutrition Information System, 1993-2005," *Public Heal. Nutr.*, vol. 12, no. 4, pp. 444–454, 2009.
- [11] Who and M. Chan, "Haemoglobin concentrations for the diagnosis of anaemia and assessment of severity," *Geneva, Switz. World Heal. Organ.*, pp. 1–6, 2011.
- [12] S. Duench, T. Simpson, L. W. Jones, J. G. Flanagan, and D. Fonn, "Assessment of variation in bulbar conjunctival redness, temperature, and blood flow," *Optom. Vis. Sci.*, vol. 84, no. 6, pp. 511–516, 2007.
- [13] C. F. Doeller, C. Barry, and N. Burgess, "From Cells to Systems," *Neurosci.*, vol. 18, no. 6, pp. 556–566, 2012.
- [14] Asbury; Vaughan, *General Ophtalmology*, 18th editi. .
- [15] D. Putra, *Pengolahan Citra Digital - Darma Putra - Google Buku*. C.V ANDI OFFSET, 2010.
- [16] P. D, *Pengolahan Citra Digital*. ANDI OFFSET, 2010.
- [17] A. Kadir and A. Susanto, *Teori dan Aplikasi Pengolahan Citra*. Yogyakarta: ANDI OFFSET, 2013.
- [18] D. N. Maharsi, J. Halomoan, and R. D. Atmaja, "Klasifikasi Serat Miring Pada Kayu Menggunakan Ekstraksi Ciri Statistik Berdasarkan Pada Pengolahan Citra," vol. 2, no. 1, pp. 209–216, 2015.
- [19] A. S. Nugroho, D. Handoko, and A. B. Witarto, "Support Vector Machine Teori dan Aplikasinya dalam Bioinformatika," p. 1, 2003.