

Analisis Perbandingan KNN dengan SVM untuk Klasifikasi Penyakit Diabetes Retinopati berdasarkan Citra Eksudat dan Mikroaneurisma

SUCI AULIA, SUGONDO HADIYOSO, DADAN NUR RAMADAN

Program Studi D3 Teknik Telekomunikasi Fakultas Ilmu Terapan
Telkom University

sucia@tass.telkomuniversity.ac.id

ABSTRAK

Penelitian mengenai pengklasifikasian tingkat keparahan penyakit Diabetes Retinopati berbasis image processing masih hangat dibicarakan, citra yang biasa digunakan untuk mendeteksi jenis penyakit ini adalah citra optik disk, mikroaneurisma, eksudat, dan hemorrhages yang berasal dari citra fundus. Pada penelitian ini telah dilakukan perbandingan algoritma SVM dengan KNN untuk klasifikasi penyakit diabetes retinopati (mild, moderate, severe) berdasarkan citra eksudat dan mikroaneurisma. Untuk proses ekstraksi ciri digunakan metode wavelet pada masing-masing kedua metode tersebut. Pada penelitian ini digunakan 160 data uji, masing-masing 40 citra untuk kelas normal, kelas mild, kelas moderate, kelas severe. Tingkat akurasi yang diperoleh dengan menggunakan metode KNN lebih tinggi dibandingkan SVM, yaitu 65 % dan 62%. Klasifikasi dengan algoritma KNN diperoleh hasil terbaik dengan parameter $K=9$ cityblock. Sedangkan klasifikasi dengan metode SVM diperoleh hasil terbaik dengan parameter One Against All.

Kata Kunci : Diabetic Retinopathy, KNN , SVM, Wavelet.

ABSTRACT

Research based on severity classification of the disease diabetic retinopathy by using image processing method is still hotly debated, the image is used to detect the type of this disease is an optical image of the disk, microaneurysm, exudates, and bleeding of the image of the fundus. This study was performed to compare SVM method with KNN method for classification of diabetic retinopathy disease (mild, moderate, severe) based on exudate and microaneurysm image. For feature extraction uses wavelet method, and each of the two methods. This study made use of 160 test data, each of 40 images for normal class, mild class, moderate class, severe class. The accuracy obtained by KNN higher than SVM, with 65% and 62%. KNN classification method achieved the best results with the parameters $K = 9$, cityblock. While the classification with SVM method obtained the best results with parameters One against all .

Keywords : Diabetic Retinopathy, KNN, SVM, Wavelet.

I. PENDAHULUAN

Penelitian untuk mendeteksi penyakit *Diabetic Retinopathy* (DR) berdasarkan klasifikasi jenisnya (*mild, moderate, severe*) telah banyak dilakukan, diantaranya adalah penelitian "Simulasi Untuk Klasifikasi Retinopati Diabetes Nonproliferasif Berdasarkan Mikroaneurisma dan Hemorrhages" (**Zahara, 2011**), yaitu klasifikasi jenis penyakit DR menggunakan citra *optik disk, eksudat, dan mikroaneurisma* berbasis *basic image processing* dengan tingkat akurasi 64%. Penelitian lainnya yaitu, deteksi penyakit diabetes retinopati dengan *exudate* sebagai parameter dengan menggunakan transformasi wavelet untuk segmentasi citra dan menggunakan algoritma jaringan saraf tiruan untuk mengklasifikasi. Dengan metode tersebut diperoleh tingkat akurasi sebesar 90% (**Riliadi, 2013**), tetapi pada penelitian ini hanya mendeteksi retina normal dan retinopati diabetes tanpa ada klasifikasi lain .

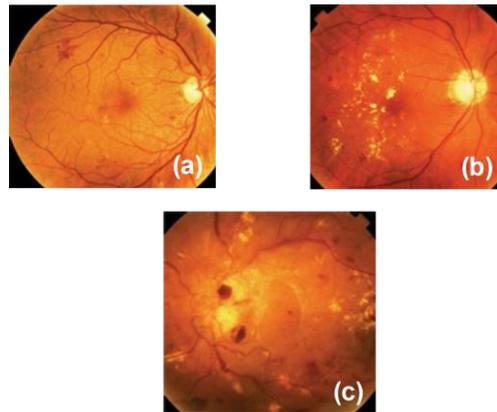
Pada penelitian ini, citra fundus yang digunakan untuk klasifikasi DR tidak hanya citra mikroaneurisma saja tetapi juga menggunakan citra eksudat, namun citra optik disk nya dihilangkan terlebih dahulu dengan *preprocessing*. Metode yang digunakan untuk klasifikasi DR adalah SVM (*Support Vector Machines*), SVM merupakan *machine learning algorithm* yang sering dipakai untuk proses klasifikasi karena dapat dengan mudah untuk diimplementasikan dan secara umum memiliki performansi yang baik dibidang *pattern recognition*. Selain SVM, digunakan juga metode KNN sebagai pembandingnya. Rajpoot (**Rajpoot, 2004**) telah melakukan penelitian untuk pengklasifikasian tekstur menggunakan Wavelet dan *Support Vector Machines* dengan rata-rata error 7.6%. Berdasarkan pada referensi tersebut, maka pada penelitian ini digunakan wavelet pada proses ekstraksi ciri baik untuk klasifikasi dengan SVM maupun KNN.

Citra fundus yang digunakan pada penelitian ini diperoleh dari Rumah Sakit Mata Cicendo Bandung, sebanyak 100 citra. Dari 100 citra tersebut, 60 citra dipakai untuk citra latih dan 40 citra untuk citra uji. Setiap citra telah diberikan kategori (kelas normal, DR *mild*, DR *moderate*, dan DR *severe*) oleh dokter spesialis mata.

1.1 Diabetic Retinopathy

Retinopati diabetes adalah suatu mikroangiopati progresif yang ditandai oleh kerusakan dan sumbatan pada pembuluh darah halus retina. Kelainan patologik yang paling dini adalah penebalan membran basal endotel kapiler dan penurunan jumlah perisit (Tjandrasa, 2013) . Secara umum klasifikasi retinopati diabetes dibagi menjadi 2, yaitu *Non-Proliferasif Diabetic Retinopathy* (NPDR), dan *Preproliferasif Diabetic Retinopathy* (PDR). NPDR Adalah *stage* awal dari diabetes retinopati, pada *stage* ini, pembuluh darah kecil pada retina mengalami pendarahan atau bocor, cairan yang bocor ini menyebabkan retina membengkak dan membentuk gumpalan-gumpalan atau *exudate*. Ada tiga klasifikasi dari NPDR (Santosa, 2005) seperti yang diperlihatkan pada Gambar 1, yaitu:

- a) *Mild NPDR* : Paling tidak terdapat satu mikroaneurisma dan pendarahan karena pembuluh darah pada retina pecah. Pada tahap ini pasien disarankan menemui dokter mata secara rutin sekurang-kurangnya 1 kali setahun.
- b) *Moderate NPDR* : *Hemorrhages* dan mikroaneurisma berada paling tidak di satu kuadran yang sama. Jumlah mikroaneurisma semakin banyak, lebih banyak dibandingkan dengan Mild NPDR.
- c) *Severe NPDR* : Jika mikroaneurisma dan *intraretinal hemorrhages* semuanya berada diempat kuadran yang sama.



Gambar 1. Citra Retina (a) Mild NPDR (b) Moderate NPDR (c) Severe NPDR (Rajpoot, 2004)

Pada penelitian ini, tipe *non-proliferasif* ditandai dengan munculnya:

a. *Mikroaneurisma*

Mikroaneurisma adalah penonjolan dinding kapiler berbentuk gelembung, disebabkan oleh kelemahan dinding kapiler, sebagai akibat dari hilangnya sel perisit. Ukuran mikroaneurisma berkisar antara 12-100 μ , terdapat disisi kapiler berwarna kekuningan.

b. *Exudate*

Exudate atau lemak lemak protein dibagi menjadi dua, yaitu:

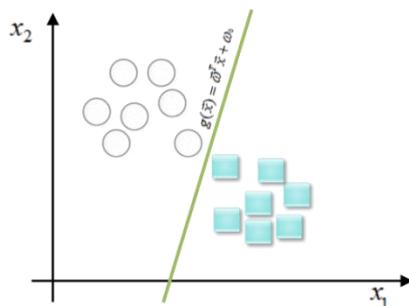
1. *Hard Exudate*, berwarna kuning karena eksudasi plasma yang lama. Pada angiografi fluoresin tampak sebagai kebocoran fluoresin diluar pembuluh darah. Terutama terdiri dari lipid yang didapatkan pada *hiperlipoproteinemia*.
2. *Cotton Wool patch*, berwarna putih, tidak berbatas tegas, dihubungkan dengan iskemik retina.

1.2 Support Vector Machines (SVM)

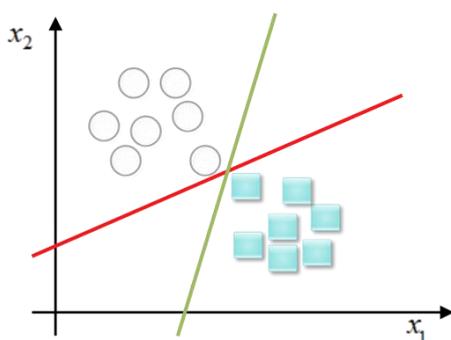
SVM merupakan salah satu metode unggulan dibidang *pattern recognition*, sebagai algoritma yang terhitung masih baru (1992), SVM berkembang pesat karena berprinsip *Structural Risk Minimization* (SRM) dengan tujuan menemukan *hyperplane* terbaik untuk memisahkan dua buah kelas pada suatu *space* sehingga algoritma ini cocok untuk diimplementasikan sebagai *clasificator*.

Berbeda dengan strategi *neural network* yang berusaha mencari *hyperplane* pemisah antar *class*, SVM berusaha menemukan *hyperplane* yang terbaik pada *input space*. Prinsip dasar SVM adalah *linear classifier*, dan selanjutnya dikembangkan agar dapat bekerja pada *problem non-linear*. dengan memasukkan konsep *kernel trick* pada ruang kerja berdimensi tinggi.

Konsep SVM adalah mendesain sebuah *hyperplane*¹ yang dapat mengklasifikasikan seluruh data training menjadi dua buah kelas, pada Gambar 2 memperlihatkan beberapa *pattern* yang merupakan anggota dari dua buah *class* yang berbentuk lingkaran dan kotak. Berbagai alternatif garis pemisah (*discrimination boundaries*) ditunjukkan pada Gambar 3.

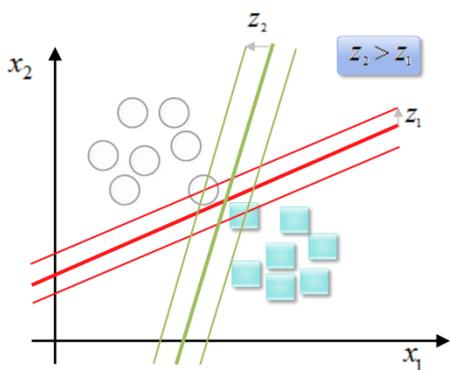


Gambar 2. Hyperplane mengklasifikasikan data menjadi dua kelas.



Gambar 3. Mencari hyperplane pemisah terbaik antar kelas.

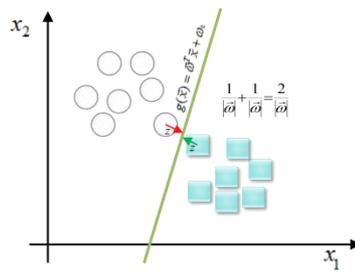
Hyperplane terbaik antara kedua class dapat ditemukan dengan cara mengukur margin hyperplane tersebut dan mencari titik maksimalnya. Margin adalah jarak antara hyperplane dengan pattern terdekat dari masing-masing kelas, seperti yang terlihat pada Gambar 4. Pattern yang paling dekat ini disebut sebagai support vector.



Gambar 4. Support vector, jarak terdekat dengan masing-masing kelas.

Garis solid hijau pada Gambar 5 menunjukkan hyperplane yang terbaik, yaitu yang terletak tepat pada tengah-tengah kedua kelas, sedangkan lingkaran dan kotak yang berada dalam margin Z_2 disebut sebagai support vector. Usaha untuk mencari lokasi hyperplane ini merupakan inti dari proses pembelajaran pada SVM.

¹ hyperplane dalam ruang vector berdimensi d adalah affine subspace berdimensi $d-1$ yang membagi ruang vector tersebut ke dalam dua bagian, yang masing-masing berkorespondensi pada class yang berbeda (Riliadi,2013)



Gambar 5. *Hyperplane* terbaik garis berwarna hijau.

Dataset pelatihan didefinisikan sebagai:

$$X1 \in Rp \tag{1}$$

dengan;

$$Y1 \in \{-1, +1\}, i=1, \dots, n \tag{2}$$

Fungsi *hyperplane* didefinisikan dengan persamaan:

$$f(x) = wx + b = 0 \tag{3}$$

$$W = (w1, w2, w3, \dots, wp) \tag{4}$$

w adalah bobot vektor *hyperplane* dan b = mendefinisikan bias.

Agar margin menjadi maksimal maka digunakan persamaan optimasi SVM untuk kasus klasifikasi linear di dalam *primal space*, yaitu:

$$\min \frac{1}{2} \|w\|^2 \tag{5}$$

dengan

$$y1(b + wxi) \geq 1, i = 1, \dots, n \tag{6}$$

Sedangkan untuk kasus *non-linear* dipisahkan dengan konsep *soft margin* yang diperkenalkan di SVM (Cristianini, 2000). Konsep Soft margin SVM adalah meminimalkan kesalahan klasifikasi (*misclassification error*) dengan memperkenalkan *slack variable*.

$$\varepsilon_i \geq 0, i = 1, \dots, n. \tag{7}$$

Seperti yang diperlihatkan pada Gambar 6:

1. Nilai variabel *slack* untuk data klasifikasi yang benar adalah $\varepsilon_i = 0$.
2. Nilai variabel *slack* untuk data, ada diantara margin $0 \leq \varepsilon_i \leq 1$.
3. Untuk data klasifikasi yang salah, nilai variabel *slack*nya adalah $\varepsilon_i = 1$.
4. Jumlah nilai yang *error* (variabel *slack*) dikalikan dengan C.

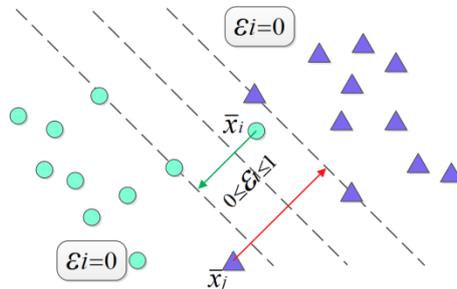
Nilai C berdasarkan *trade-off* antara margin maksimum dan *error* yang dapat ditoleransi. Dengan konsep *softmargin* SVM optimasi dibuat persamaan berikut :

$$\tau(w) = \frac{1}{2} \|w\|^2 + C \sum_{i=1}^n \varepsilon_i \tag{8}$$

Dimana :

$$\varepsilon_i \geq 0 \tag{9}$$

$$y_i (b + wx_i) \geq 1 - \varepsilon_i, i = 1, \dots, n \tag{10}$$



Gambar 6. SVM dengan variabel *slack*

Problem optimasi diselesaikan dengan mengenalkan *fungsi Lagrangian*. Dengan kondisi ketika;

$$\alpha_i \geq 0, i = 1, \dots, n \tag{11}$$

maka persamaannya adalah,

$$w = \sum_{i=1}^n \alpha_i y_i x_i \tag{12}$$

Sedangkan ketika kondisi *support vector* data ada di $\alpha_i > 0$, nilai b diganti dengan;

$$(b + (w \cdot x_i)) = y_i(1 - \varepsilon_i) \tag{13}$$

$$b = y_i \cdot (1 - \varepsilon_i) - (w \cdot x_i) \tag{14}$$

1.3 KNN

KNN merupakan algoritma paling sederhana diantara algoritma lainnya dalam hal memprediksikan suatu kelas pada suatu sampel. Untuk mengklasifikasikan suatu kelas, KNN bekerja berdasarkan jarak terdekat ketetanggaaan antar objek dengan cara sebagai berikut (Sudha, 2012) :

1. Menghitung jarak dari seluruh *training vectors to test vectors*.
2. Ambil nilai K yang paling dekat nilai vektornya.
3. Hitung nilai rata-ratanya.

Jika nilai k= 1, maka objek diasumsikan sebagai anggota kelas dari tetangga terdekatnya. Nilai k terbaik tergantung dari banyaknya data. Secara umum semakin tinggi nilai k makan akan mengurangi pengaruh noise pada proses klasifikasi. Untuk menghitung jarak pada seluruh data latih, pengukurannya dapat dilakukan dengan beberapa metoda seperti *Euclidean distance, Cityblock distance, Cosine distance, Correlation, Hamming distance*.

1.4 Haar Wavelet

Trasformasi dari 2D Haar wavelet dapat dilihat dari contoh matriks 4x4 seperti yang ditunjukkan pada Gambar 7 berikut.

$$\begin{bmatrix} 30 & 16 & 51 & 24 \\ 38 & 19 & 11 & 6 \\ 28 & 45 & 53 & 5 \\ 29 & 44 & 52 & 59 \end{bmatrix}$$

Gambar 7. Matriks array 2D

Kemudian dihitung jumlah rata-rata dan selisih setiap baris dan kolomnya, langkah pertama adalah menghitung nilai rata-rata dan selisih setiap baris.

Menghitung rata-rata baris ke-1

$$\frac{30+16}{2} = 23, \quad \frac{51+24}{2} = 37.5 \quad (15)$$

Selisih baris ke-1 : $30 - 23 = 7$, dan $51 - 37.5 = 13.5$

Maka hasil transformasi baris ke-1 menjadi : $[23 \ 37.5 \ 7 \ 13.5]$

Kemudian lakukan operasi yang sama pada nilai rata-rata : $[23 \ 37.5]$

maka hasil akhir transformasi baris ke-1 menjadi: $[30.35 \ -7.25 \ 7 \ 13.5]$

Matriks baru hasil dari transformasi setiap baris dapat dilihat pada Gambar 8 berikut.

$$\begin{bmatrix} 30,5 & -7,25 & 7 & 13,5 \\ 18,5 & 10 & 9,5 & 2,5 \\ 32,75 & 3,75 & -8,5 & 24 \\ 46 & -9,5 & -7,5 & -3,5 \end{bmatrix}$$

Gambar 8. Matriks hasil transformasi baris dari matriks array 2D gambar 7.

Kemudian dilakukan juga operasi yang sama untuk setiap kolom, sehingga diperoleh hasil akhir transformasi seperti pada gambar 9.

$$\begin{bmatrix} 31,25 & 31 & 41,75 & 23,5 \\ 2,75 & -13,5 & -10,75 & -8,5 \\ -4 & -1,5 & 20 & 9 \\ -0,5 & 0,5 & 0,5 & -27 \end{bmatrix}$$

Gambar 9. Matriks hasil transformasi kolom dari matriks array 2D gambar 8.

Dari matriks tersebut, matriks asli dapat direkonstruksi kembali dengan menggunakan operasi reverse dari rata-rata dan nilai selisihnya. Oleh karena itu Haar Wavelet ini mentransformasikan suatu input dengan sifat *loss of information*.

II. METODOLOGI PENELITIAN

Tujuan dari penelitian ini adalah mengimplementasikan dan menganalisis metode SVM dan KNN untuk menentukan klasifikasi penyakit retinopati diabetes melalui ciri yang ada pada retina. Maka untuk mencapai tujuan tersebut, langkah-langkah metodologi penelitian yang dilakukan adalah sebagai berikut :

1. Pencarian referensi meliputi studi pustaka tentang:
 - a. Pengolahan citra digital (*preprocessing*, segmentasi citra)
 - b. Metode *Haar Wavelet*
 - c. Algoritma *Support Vector Machine*
 - d. Algoritma KNN
 - e. Penyakit Retinopati Diabetes *Non Proliferatif*
2. Pengumpulan data
Bertujuan untuk mendapatkan data citra yang akan menjadi *input* dalam sistem. Data didapat dari Rumah Sakit Mata Cicendo Bandung dan Klinik Spesialis Mata Netra.
3. Implementasi perangkat lunak
Sistem dirancang dengan menggunakan Matlab R2012b.
4. Analisis performansi
Melakukan analisis performansi pengidentifikasian penyakit retinopati diabetes menggunakan citra retina berdasarkan mikroneurisma dan eksudat.
5. Membandingkan Metode
Membandingkan metode mana yang paling baik untuk melakukan klasifikasi penyakit retinopati diabetes
6. Mengambil kesimpulan.
Mengambil kesimpulan setelah melakukan pengujian klasifikasi retinopati diabetes nonproliferatif.

III. HASIL DAN DISKUSI

3.1 Deteksi Mikroaneurisma Dan Eksudat

Berikut adalah langkah-langkah untuk mendeteksi mikroaneurisma dan eksudat pada input citra fundus :

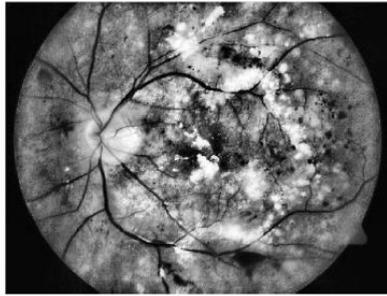
3.1.1 Deteksi Mikroaneurisma

A. Preprosesing:

Pada proses ini yang dilakukan adalah mengubah warna citra input (diambil hanya layer-2 saja dari *RGB*) ke *Grayscale* untuk mempermudah proses deteksi mikroaneurisma

B. Adaptif histogram ekualisasi :

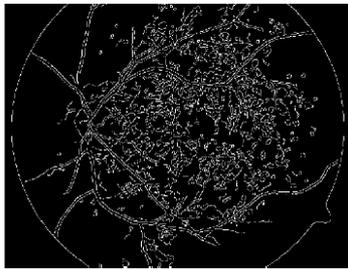
Adaptif histogram ekualisasi dilakukan untuk memperjelas mikroaneurisma yang berada didekat pembuluh darah. Hasilnya dapat dilihat pada Gambar 10.



Gambar 10. Citra fundus hasil adaptif histogram ekualisasi

C. Canny edge detection:

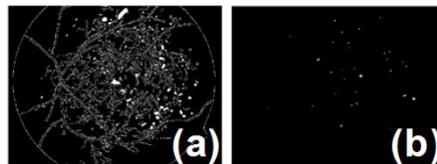
Selanjutnya dilakukan deteksi tepi dengan *canny* pada citra hasil ekualisasi adaptif histogram, seperti yang terlihat pada Gambar 11. Pada proses ini, nilai *threshold* diatur agar *optic disc* hilang.



Gambar 11. Citra setelah dilakukan deteksi tepi dengan *canny*

D. Filling :

Hasil dari *filling* dapat dilihat pada Gambar 12, proses yang terjadi adalah penebalan pada calon mikroaneurisma kemudian dikurangkan hasilnya dengan citra hasil deteksi tepi sehingga diperoleh citra yang hanya terdapat mikroaneurisma saja.



Gambar 12. (a) Citra setelah di *filling* (b) mikroaneurisma

3.1.2 Deteksi Eksudat

Dengan langkah yang sama pada proses deteksi mikroaneurisma, diperoleh citra biner yang hanya terdiri dari eksudat saja seperti Gambar 13 berikut.



Gambar 13. Citra setelah optik disk dihilangkan

3.2 Haar Wavelet Dan Ekstraksi Ciri

Gabungan dari citra biner mikroaneurisma dan eksudat, yaitu gambar 11 dan gambar 12 akan menjadi masukan dalam proses dekomposisi, citra akan didekomposisi dengan menggunakan transformasi haar wavelet dari level 1 hingga level 7. Selanjutnya citra akan diekstrak dengan metode ekstraksi ciri statistik orde pertama *mean* dan *variance*, ciri latih akan disimpan untuk menjadi perbandingan ciri citra latih pada tahap selanjutnya. Citra latih terdiri dari 60 buah citra fundus, dimana masing-masing kelas (*normal*, *mild*, *moderate*, *severe*) memiliki 15 citra.

3.3 Klasifikasi DR

Pada penelitian ini, proses klasifikasi dilakukan dengan menggunakan algoritma SVM *One Versus One (OVO)* dan *One Versus All (OVA)* dan algoritma KNN (*cosine*, *cityblock*, *euclidean* dan *correlation*) sebagai pembandingnya.

3.3.1 Klasifikasi dengan SVM

Tabel 1 menunjukkan hasil pengujian dari proses klasifikasi menggunakan metoda SVM .

Tabel 1. Tingkat Akurasi Dengan Metoda Statistik Ekstraksi Ciri *Mean*

Wavelet Level	OVO (%)	OVA (%)
1	16	48
2	24	56
3	34	62
4	24	56
5	20	48
6	20	42
7	48	40

Dari Tabel 1, dengan menggunakan ciri statistik *mean* diperoleh tingkat akurasi maksimum 62%, nilai tersebut diperoleh pada saat SVM menggunakan metode *one versus all* dengan parameter wavelet pada level 3.

Tabel 2. Tingkat Akurasi Dengan Metoda Statistik Ekstraksi Ciri *Variance*

Wavelet Level	OVO (%)	OVA (%)
1	24	34
2	24	38
3	20	38
4	28	32
5	40	34
6	56	50
7	34	44

Dari Tabel 2, dengan menggunakan ciri statistik *varian* diperoleh tingkat akurasi maksimum 56%, nilai tersebut diperoleh pada saat SVM menggunakan metode *one versus one* dengan parameter wavelet pada level 6.

3.3.2 Klasifikasi dengan KNN

Tabel 3. Tingkat Akurasi Algoritma KNN Ciri Statistik *Mean* Dengan *Cosine Distance*

Cosine					
Wavelet Level	K				
	1	3	5	7	9
1	35	32,5	22,5	32,5	27,5
2	37,5	20	20	32,5	27,5
3	42,5	30	25	37,5	27,5
4	40	32,5	32,5	27,5	25
5	37,5	27,5	35	35	32,5
6	35	32,5	35	30	25
7	40	42,5	35	32,5	30

Dari Tabel 3 dengan menggunakan *cosine distance* diperoleh nilai maksimum 42.5% pada *wavelet* level 3 dan k = 9

Tabel 4. Tingkat Akurasi Algoritma KNN Ciri Statistik *Mean* Dengan *Cityblok Distance*

Citiblock					
Wavelet Level	K				
	1	3	5	7	9
1	52,5	57,5	52,5	57,5	65
2	42,5	50	45	60	57,5
3	40	47,5	47,5	42,5	47,5
4	52,5	45	37,5	40	42,5
5	55	45	47,5	27,5	35
6	42,5	40	35	40	32,5
7	35	35	35	37,5	35

Dari Tabel 4 dengan menggunakan *cityblok distance* diperoleh nilai maksimum 65% pada *wavelet* level 1 dan k = 9.

Tabel 5. Tingkat Akurasi Algoritma KNN Ciri Statistik *Mean* Dengan *Euclidean Distance*

Euclidean					
Wavelet Level	K				
	1	3	5	7	9
1	50	57,5	52,5	62,5	62,5
2	47,5	42,5	47,5	55	57,5
3	60	47,5	47,5	47,5	50
4	55	40	40	45	40
5	52,5	45	35	32,5	37,5
6	45	42,5	45	40	37,5
7	37,5	40	40	32,5	35

Dari Tabel 5 dengan menggunakan *euclidean distance* diperoleh nilai maksimum 62.5% pada *wavelet* level 1 dan $k = 9$.

Tabel 6. Tingkat Akurasi Algoritma KNN Ciri Statistik *Mean* Dengan *Correlation Distance*

Correlation					
Wavelet Level	K				
	1	3	5	7	9
1	37,5	45	42,5	32,5	30
2	37,5	25	12,5	32,5	25
3	40	30	27,5	27,5	30
4	32,5	35	30	20	25
5	37,5	30	35	37,5	25
6	35	35	35	32,5	25
7	40	42,5	35	32,5	30

Dari Tabel 6 dengan menggunakan *correlation distance* diperoleh nilai maksimum 45% pada *wavelet* level 1 dan $k = 3$.

Tabel 7. Tingkat akurasi algoritma KNN ciri statistik *variance* dengan *cosine distance*

Cosine					
Wavelet Level	K				
	1	3	5	7	9
1	52,5	55	57,5	62,5	65
2	52,5	45	42,5	52,5	47,5
3	60	52,5	50	45	42,5
4	55	37,5	20	37,5	32,5
5	37,5	27,5	30	30	30
6	42,5	40	32,5	30	37,5
7	32,5	32,5	35	37,5	35

Dari Tabel 7 dengan menggunakan *cosine distance* diperoleh nilai maksimum 65% pada *wavelet* level 1 dan $k = 9$.

Tabel 8. Tingkat Akurasi Algoritma KNN Ciri Statistik *Variance* Dengan *Cityblock Distance*

Cityblock					
Wavelet Level	K				
	1	3	5	7	9
1	60	60	50	52,5	50
2	47,5	50	50	50	37,5
3	65	62,5	52,5	55	45
4	52,5	40	22,5	35	32,5
5	45	32,5	30	30	30
6	37,5	27,5	30	30	30
7	40	30	30	32,5	35

Dari Tabel 8 dengan menggunakan *cityblock distance* diperoleh nilai maksimum 65% pada *wavelet* level 3 dan $k = 1$.

Tabel 9. Tingkat Akurasi Algoritma KNN Ciri Statistik *Variance* Dengan *Euclidean Distance*

Euclidean					
Wavelet Level	K				
	1	3	5	7	9
1	57,5	55	50	50	45
2	50	55	55	42,5	40
3	65	57,5	47,5	42,5	40
4	52,5	47,5	25	35	37,5
5	42,5	37,5	30	22,5	30
6	40	35	27,5	25	25
7	40	27,5	35	32,5	32,5

Dari Tabel 9 dengan menggunakan *euclidean distance* diperoleh nilai maksimum 65% pada *wavelet* level 3 dan $k = 1$.

Tabel 10. Tingkat Akurasi Algoritma KNN Ciri Statistik *Variance* Dengan *Correlation Distance*

Correlation					
Wavelet Level	K				
	1	3	5	7	9
1	55	50	50	57,5	55
2	52,5	45	47,5	47,5	45
3	57,5	62,5	50	47,5	47,5
4	57,5	37,5	20	40	32,5
5	35	30	35	32,5	32,5
6	42,5	40	32,5	30	37,5
7	32,5	32,5	37,5	32,5	35

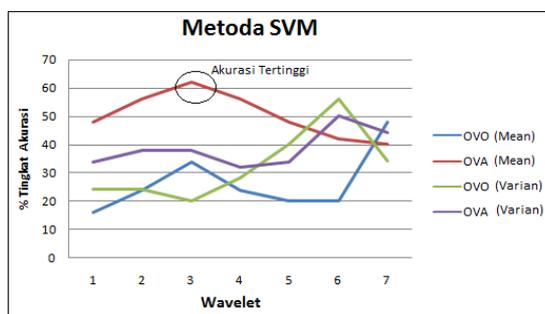
Dari Tabel 10 dengan menggunakan *euclidean distance* diperoleh nilai maksimum 62.5% pada *wavelet* level 3 dan $k = 3$.

2.4 Analisis Perbandingan Algoritma SVM dan KNN

Dari 160 data uji citra fundus untuk klasifikasi DR berdasarkan tingkat keparahannya (*mild*, *severe*, dan *moderate*) dan normal, dilakukan pengujian. Adapun skenario pengujianya adalah sebagai berikut :

- I. Pengujian dengan algoritma SVM *One Versus One (OVO)* dan *One Versus All (OVA)*, masing-masing metoda diujikan dengan menggunakan ciri statistik *mean* dan *variance* serta haar wavelet level 1 – 7.

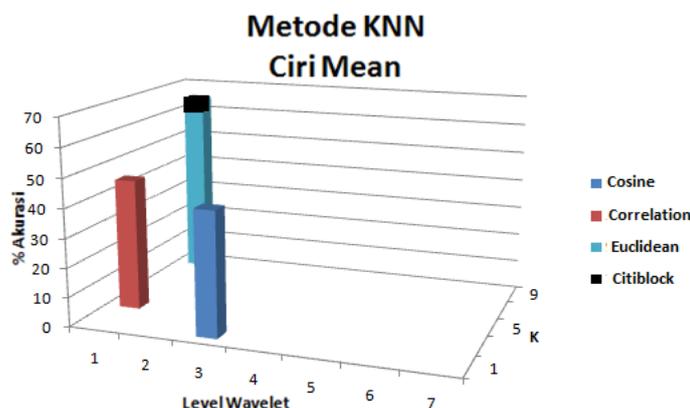
Dari kedua ciri statistik tersebut (*mean* dan *variance*) diperoleh tingkat akurasi maksimum 62 % untuk SVM dengan metoda *One Versus All* seperti yang diperlihatkan pada Gambar 14.



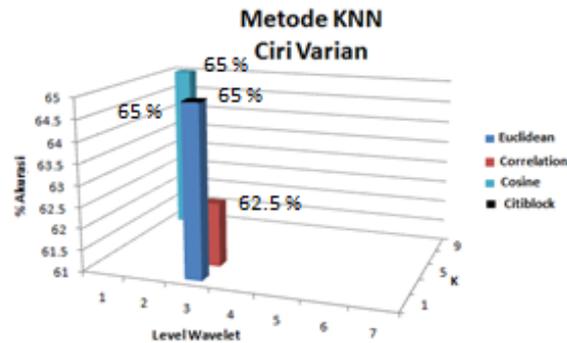
Gambar 14. Grafik akurasi algoritma SVM

II. Pengujian dengan algoritma KNN dengan algoritma *distance* yang digunakan adalah *cosine*, *cityblock*, *euclidean*, dan *correlation*. Sama halnya seperti pada pengujian dengan algoritma SVM, pada algoritma KNN dengan masing-masing *distance* diujikan dengan menggunakan ciri statistik *mean* dan *variance* serta haar wavelet level 1 – 7.

Dari hasil pengujian dengan algoritma KNN menggunakan ciri statistik mean dengan metode *cosine distance*, *cityblock distance*, *euclidean distance*, dan *correlation distance* diperoleh nilai akurasi maksimum 65 % dengan K=9 metoda *cityblok distance* pada wavelet level = 1 seperti yang ditunjukkan pada gambar 15 . Sedangkan pengujian dengan ciri statistik *variance* diperoleh nilai akurasi maksimum 65 % dengan metode *cosine distance*, *cityblock distance*, *euclidean distance*, dan 62.5% dengan metode *correlation distance* . Seperti yang ditunjukkan pada gambar 16, nilai akurasi maksimum 65 % diperoleh secara mayor pada wavelet level 3 dan k = 1.



Gambar 15. Grafik akurasi algoritma KNN dengan ciri statistik *mean*



Gambar 16. Grafik akurasi algoritma KNN dengan ciri statistik *variance*

Berdasarkan Gambar 14,15 dan 16 dapat dilihat bahwa tingkat akurasi maksimum untuk klasifikasi tingkat keparahan penyakit DR dengan algoritma SVM dan KNN adalah 62% dan 65%. Tingkat akurasi SVM diperoleh 62 % dengan menggunakan metode One Versus All melalui pendekatan algoritma kernel dan parameter haarwavelet pada level 3, serta ciri statistik yang digunakan adalah *mean*. Performansi KNN pada kasus ini, lebih baik dibandingkan dengan SVM. Pada KNN tingkat akurasi 65 % diperoleh relatif stabil pada $K = 9$ untuk ciri statistik *mean* dan $K = 1$ untuk ciri statistik *variance* (berkebalikan). Selain nilai K , parameter algoritma *distance* yang digunakanpun mempengaruhi. Dari hasil pengujian untuk kedua metode ciri statistik, *cityblock distance* memperoleh nilai akurasi yang sama dan maksimum yaitu 65%.

IV. KESIMPULAN

Penelitian ini mempresentasikan suatu perbandingan antara algoritma SVM dan KNN sebagai *classifiers* tingkat keparahan penyakit *Diabetic Retinopati* (DR) berdasarkan eksudat dan mikroaneurisma yang terdiri dari 60 citra latih dan 160 citra uji dari citra fundus RS. Cicendo Bandung. Klasifikasi DR yang diamati pada penelitian ini adalah kelas *mild, moderate*, dan *severe*. Adapun hasil yang diperoleh sebagai berikut :

1. Klasifikasi dengan algoritma SVM diperoleh tingkat akurasi maksimum 62 % dengan metoda OVA ciri statistik *mean*.
2. Klasifikasi dengan algoritma KNN diperoleh nilai akurasi maksimum 65 % dengan $K=9$ metoda *cityblok distance* pada wavelet level = 1, ciri statistik *mean* dan *variance*.

DAFTAR PUSTAKA

- Zahara, Haula Siva. (2011). Simulasi Untuk Klasifikasi Retinopati Diabetes Nonproliferatif Berdasarkan Mikroaneurisma dan Hemorrhages : Fakultas Elektro Dan Komunikasi. Institut Teknologi Telkom.
- Riliandi, Gladi Yudha. (2013). Deteksi diabetes melali citra retina dengan menggunakan Transformasi wavelet dan learning vector quantization : Institut Teknologi Telkom.
- Rajpoot, K, M., and Rajpoot, N, M.,(2004). *Wavelets and Support Vector Machines for Texture Classification* : Proceedings of INMIC.
- Tjandrasa, H., Eka Putra, R., Wijaya, A., Arieshanti, I., (2013). *Classification of Non-Poliferative Diabetic Retinopathy Based on hard Exudates Using Soft Margin SVM*. Malaysia: IEEE International Conference on Control System, Computing and Engineering.

- Santosa, Budi. (2005). *Tutorial Vector Machine* : Fakultas Teknik Industri. Institut Teknologi Surabaya.
- Cristianini, N., and Shawe-Taylor, J., (2000). *An Introduction to Support Vector Machines* : Cambridge University Press.
- Sudha, L. P., and Bhavani, R., (2012). *Gait Base Gender Identification Using Statistical Pattern Classifiers* : International Journal of Computer Application (0975-8887), Vol.40, No. 8.
- Antal, B., Hajdu, A., 2012. *An Ensemble-Base system for Microaneurysm Detection and Diabetic Retinopathy Grading* : IEEE Transaction on biomedical engineering, Vol. 59, No. 6.
- Gitasari, Ratna Ayu. 2015. *Klasifikasi Penyakit Diabetes Retinopati Berdasarkan Citra Digital Dengan Menggunakan Metode Wavelet dan Support Vector Machine* : Fakultas Teknik Elektro. Universitas Telkom.
- Kerami, D., dan Murfi, H., 2004. *Kajian Kemampuan Generalisasi Support Vector Machine Dalam Pengenalan Jenis Splice Pada Barisan DNA* : Makara Sains, Vol. 8, No. 3, 89-95.
- Vaughan DG, Asbury T, Eva PR. 2000. *Oftalmologi Umum*. Edisi ke-14. Jakarta: Widya Medika. 211-4.