

Penerapan Algoritme *Support Vector Machine* Terhadap Klasifikasi Tingkat Risiko Pasien Gagal Ginjal

Ratna Ayu Wijayanti¹, Muh. Tanzil Furqon², Sigit Adinugroho³

Program Studi Teknik Informatika, Fakultas Ilmu Komputer, Universitas Brawijaya
Email: ¹ratnanawijaya@gmail.com, ²m.tanzil.furqon@ub.ac.id, ³sigit.adinu@ub.ac.id

Abstrak

Gagal ginjal merupakan suatu kondisi bahwa ginjal tidak dapat menjalankan fungsinya secara tepat. Di seluruh dunia kasus mengenai gagal ginjal yang mengalami peningkatan setiap tahun adalah gagal ginjal kronik. Di Indonesia menurut data dari penetri (Persatuan Netrologi Indonesia) diperkirakan mencapai 70 ribu penderita penyakit gagal ginjal kronik. Untuk membantu mengetahui status fungsi ginjal seseorang dibuat suatu sistem yang dapat melakukan proses klasifikasi tingkat risiko pasien gagal ginjal menggunakan algoritme *support vector machine* (SVM) dan strategi *one-against-all*. Alur dari penelitian yaitu menggunakan analisis korelasi untuk melihat hubungan antar fitur, melakukan normalisasi agar nilai data berada pada interval yang sama, perhitungan *kernel RBF*, melakukan proses *training* dengan *sequential training*, kemudian menggunakan *one-against-all* untuk proses klasifikasi. Pengujian akhir dari penelitian ini menghasilkan nilai rata-rata akurasi sebesar 83,998% dan akurasi tertinggi sebesar 98,33% dengan menggunakan rasio perbandingan data 80%:20%, nilai parameter λ (*lambda*) = 1, γ (*gamma*) = 0,0001, σ kernel RBF = 2, C (*Complexity*)=0,0001 dan jumlah iterasi SVM=100. Berdasarkan hasil tersebut dapat disimpulkan bahwa algoritme SVM dan strategi *one-against-all* dapat digunakan untuk klasifikasi tingkat risiko pasien gagal ginjal.

Kata kunci: klasifikasi, gagal ginjal, support vector machine, one-against-all, analisis korelasi

Abstract

*Kidney failure is a condition that the kidneys can not function properly. Worldwide cases of kidney failure are on the rise every year is chronic renal failure. In Indonesia the disease sufferers of chronic kidney failure are categorized as very high. According to data from the penetri (Union of Netrologi Indonesia) was estimated at 70 thousand kidney failure chronic disease sufferers. To help knowing the status of kidney function someone, we made an intelligent system using support vector machine (SVM) algorithm for classification of risk of kidney failure and using one-against-all strategy. The flow of research those are using correlation analysis to look at the relationships between features, with normalization for data values are at the same interval, the calculation kernel RBF, do the training process with sequential training, then use one-against-all for the process of classification. This study The final test result of this research obtained the average value of accuracy is 83,998% and the highest accuracy is 98,33% using the ratio of data 80%: 20%, with the parameter value of λ (*lambda*) = 1, γ (*gamma*) = 0,0001, σ for kernel RBF = 2, C (*Complexity*) = 0,0001 and the number of iterations = 100. Based on these results it can be concluded that the SVM algorithm and strategy one-against-all can be used for classification of risk of kidney failure.*

Keywords: classification, kidney failure, support vector machine, one-against-all, correlation analysis

1. PENDAHULUAN

Kunci utama pada kehidupan manusia adalah kesehatan. Manusia dapat menjalani aktivitas sehari-hari dengan produktif apabila memiliki tubuh sehat, sebaliknya jika kesehatan terganggu maka akan terganggu pula

aktivitasnya. Banyak masyarakat yang mengesampingkan fungsi organ tubuh yang sangat vital untuk dirawat, salah satunya adalah ginjal. Karena ginjal mempunyai fungsi utama di dalam tubuh, yaitu dapat membersihkan darah dari produk sisa metabolisme serta toksin yang ada di dalam tubuh (Kompas, 2010). Jika

terdapat kelainan yang mengganggu ginjal, maka kemungkinan banyak penyakit yang dideritas manusia. Salah satu masalah kesehatan yang akan terus berkembang di masa depan adalah gagal ginjal. Gagal ginjal tersebut merupakan suatu kondisi bahwa ginjal tidak dapat menjalankan fungsinya secara tepat.

Di seluruh dunia kasus mengenai gagal ginjal yang selalu mengalami peningkatan setiap tahunnya adalah gagal ginjal kronik. Permasalahan tersebut sejumlah 200 kasus per juta per tahunnya di banyak negara dan akan terus meningkat pada individu yang lebih tua. Penyakit gagal ginjal kronik mengalami prevalensi global sebesar 13,4% dan menjadi penyebab kematian dengan peringkat ke-27 di dunia pada tahun 1990 serta pada tahun 2010 berada pada peringkat ke-18 secara global. Di Indonesia penderita penyakit gagal ginjal kronik tergolong sangat tinggi. Menurut data dari penetri (Persatuan Netrologi Indonesia) diperkirakan mencapai 70 ribu penderita penyakit gagal ginjal kronik (Safitri & Dewi, 2014). Dengan melihat prevalensi dari berbagai Negara bahwa masyarakat harus melakukan pencegahan dini terhadap timbulnya risiko pasien gagal ginjal maka nantinya dapat mencegah pengembangan dan memperlambat perkembangan penyakit, mengurangi komplikasi penurunan GFR (*Glomerular Filtration Rate*) dan risiko penyakit kardiovaskular, dan memperbaiki kelangsungan hidup dan kualitas hidup serta mengurangi angka kematian.

Salah satu cara untuk mencegah penurunan fungsi ginjal adalah dengan mengetahui status fungsi ginjal seseorang. Untuk membantu mengetahui status fungsi ginjal tersebut diperlukan adanya sistem yang dapat melakukan proses klasifikasi tingkat risiko pasien gagal ginjal. Pemilihan metode dan teknik dalam penyelesaian masalah ini berpengaruh pada hasil yang didapat nantinya. Salah satu metode klasifikasi yang memiliki kinerja sangat baik pada data berdimensi tinggi adalah metode *Support Vector Machine* (SVM) (Budiarti, 2017). Pengklasifikasian SVM memakai fungsi garis pemisah (*hyperplane*) yang bertujuan untuk memisahkan dua buah kelas pola. Karena data yang digunakan pada penelitian ini terdapat tiga kelas maka digunakan strategi *One-Againts-All* (OAA). OAA ini memiliki konsep dengan memandang kelas awal dianggap sebagai kelas positif dan kelas lainnya menjadi kelas negatif (Prasetyo, 2012).

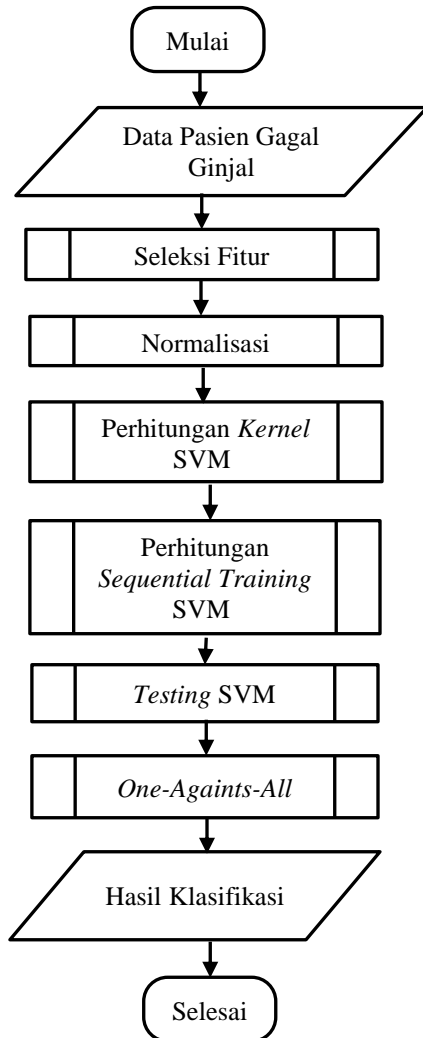
Salah satu contoh penelitian yang menerapkan algoritme *Support Vector Machine* (SVM) adalah klasifikasi tingkat kerusakan jalan pada rel kereta api yang dilakukan oleh Munawaroh. Klasifikasi yang dihasilkan berupa rusak berat, rusak sedang dan rusak ringan. Langkah algoritme yang dilakukan adalah normalisasi, menghitung kernel *polynomial d*, perhitungan matriks *hessian*, *sequential training* SVM, menghitung $f(x)$ serta melakukan klasifikasi dengan strategi *one-againts-all*. Hasil akurasi yang didapat pada penelitian ini sebesar 91,24% (Munawaroh, 2014).

Melihat permasalahan yang dijabarkan di atas maka penulis akan membangun sebuah sistem cerdas yang dapat melakukan klasifikasi tingkat risiko pasien gagal ginjal dengan menggunakan fitur dan masukan sesuai dengan penelitian di Laboratorium Klinik Sejahtera kota Probolinggo pada tahun 2013 seperti jenis kelamin, umur, urea, BUN(*Blood Urea Nitrogen*), kreatinin, *uric acid*, dan *trigliserida*. Sedangkan keluaran dari sistem ini adalah berupa tingkat risiko yang dialami pasien gagal ginjal seperti risiko normal, ringan, dan tinggi. Penulis menggunakan metode *Support Vector Machine* (SVM) dan strategi *One-Againts-All*.

2. METODOLOGI PENELITIAN

Langkah awal pada penyelesaian masalah dalam penelitian ini adalah seleksi fitur menggunakan analisis korelasi yang berfungsi mengukur keeratan (hubungan) antar fitur dalam data. Dalam analisis ini yang menunjukkan bahwa antar fitur tersebut memiliki hubungan dilihat pada nilai koefisien korelasinya. Hasil dari proses analisis tersebut bahwa fitur umur dan jenis kelamin tidak memiliki pengaruh yang kuat dan tidak memiliki keterikatan terhadap fitur tingkat risiko karena nilai koefisien korelasinya mendekati nilai 0. Selanjutnya terlebih dahulu melakukan normalisasi nilai pada masing-masing nilai data setiap fitur agar nilainya berada pada interval yang sama. Kemudian melakukan perhitungan kernel SVM, kernel yang digunakan adalah kernel RBF. Kernel tersebut memiliki pengaruh pada pemetaan data yang terbentuk. Setelah itu melakukan perhitungan proses pembelajaran dengan *sequential training* yang terdiri dari matriks *hessian*, nilai E_i , $\delta\alpha_i$, dan α_i serta melakukan proses *testing* pada data uji menggunakan *testing* SVM. Tahap yang

selanjutnya adalah *one-against-all*, tahap ini merupakan strategi yang digunakan dalam mengatasi permasalahan *multiclass* pada SVM dengan membentuk level terhadap kelas data dan yang terakhir berupa hasil klasifikasi.



Gambar 1. Alur tahapan algoritme SVM strategi *one-against-all*

2.1. Data

Dalam penelitian ini data yang digunakan adalah *dataset* penyakit gagal dari penelitian sebelumnya yang dilakukan oleh Nurul Magfirah pada tahun 2014. Data tersebut diambil dari laboratorium klinik Sejahtera Kota Probolinggo tahun 2013 berupa data hasil tes darah lengkap penyakit gagal ginjal yang terdiri dari 300 data, 7 fitur dan 3 jenis kategori tingkat risiko, yaitu normal, rendah dan tinggi. Berikut fitur-fitur yang digunakan.

1. Jenis Kelamin
2. Umur
3. Kadar Urea: batas normal dari kadar urea yaitu 10-50 mg/dl.

4. Kadar BUN: batas normal untuk kadar BUN 6-20 mg/dl.
5. Kadar Kreatinin: batas normal kadar kreatinin dalam darah untuk perempuan 0,6-1,1 mg/dl sedangkan untuk laki-laki 0,7-1,3 mg/dl.
6. Kadar Uric Acid: batas normal uric acid pada perempuan 2,4-5,7 mg/dl dan laki-laki 3,4-7,0 mg/dl
7. Kadar Trigliserida: kadar trigliserida darah, normal > 200 mg/dl, garis batas tinggi 200-250 mg/dl, tinggi > 250 mg/dl.

2.2. Analisis Korelasi

Pada penelitian ini menggunakan jenis analisis korelasi sederhana, yaitu dengan mengukur kekuatan atau keterikatan hubungan antar dua variabel. Kekuatan antar dua variabel didefinisikan erat, lemah atau tidak erat(tidak ada hubungannya sama sekali) (Steel & Torrie, 1989). Dalam korelasi terdapat koefisien korelasi, Koefisien tersebut dinotasikan sebagai *r* serta memiliki nilai antara -1 sampai 1 (-1 ≤ *r* ≤ 1) serta rumus analisis korelasi ditunjukkan pada persamaan 1 (Pramoedyo, 2013).

$$r = \frac{n \sum_{i=1}^n x_i y_i - (\sum x_i)(\sum y_i)}{\sqrt{[n \sum x_i^2 - (\sum x_i)^2][n \sum y_i^2 - (\sum y_i)^2]}} \tag{1}$$

Keterangan:

- r* = koefisien korelasi
- n* = jumlah sampel
- x* = nilai variabel *x*
- y* = nilai variabel *y*

2.3. Normalisasi

Normalisasi digunakan supaya nilai antar fitur berada pada interval yang sama. *Min-Max Normalization* adalah metode normalisasi yang sering digunakan untuk mengatasi permasalahan nilai antar fitur yang memiliki jarak terlampau jauh (Larose, 2005).

$$X^* = \left(\frac{X - \min(x)}{\max(x) - \min(x)} \right) \tag{2}$$

Keterangan:

- X** = hasil normalisasi data
- X* = data yang belum dinormalisasi
- min(*X*)= nilai minimum dari semua data
- max(*X*)= nilai maksimum dari semua data

2.4. Support Vector Machine

Support Vector Machine (SVM) adalah metode klasifikasi dengan menerapkan teori pembelajaran statistika dan dapat memberikan hasil klasifikasi yang baik, memetakan data asli

menjadi dimensi lain yang lebih tinggi dengan menerapkan teknik kernel, serta memiliki konsep memisahkan dua buah kelas dan berusaha untuk menemukan *hyperplane* terbaik (Prasetyo, 2012).

2.4.1. Sequential Training

Salah satu proses *training* pada SVM adalah *sequential training*, dengan proses tersebut dibutuhkan waktu yang lebih cepat dalam menyelesaikan permasalahan karena memiliki algoritma yang sederhana. Berikut penjelasan dari Algoritme *sequential training* (Vijayakumar, 1999).

1. Melakukan inialisasi α_i dan parameter yang lain, yaitu λ , γ , C , dan ε .

Keterangan:

α_i =lagrange multiplier, berguna untuk mencari *support vector*.

γ =gamma, berguna dalam melakukan

controlling kecepatan *training*.

C =complexity C , parameter ini digunakan dalam proses *training* yang nantinya memberikan batas nilai alfa.

ε =epsilon, digunakan dalam mengukur *error* pada klasifikasi

2. Melakukan perhitungan matriks *hessian* menggunakan persamaan 3.

$$D_{ij} = y_i y_j (K(x_i x_j) + \lambda^2) \tag{3}$$

keterangan:

x_i = data ke- i

x_j = data ke- j

y_i = kelas data ke- i

y_j = kelas data ke- j

n = jumlah data

$K(x_i, x_j)$ = fungsi *kernel*

3. Menghitung nilai E_i , $\delta\alpha_i$, dan α_i pada data yang dipakai mulai dari data ke- i sampai ke- j dengan persamaan 4.

$$E_i = \sum_{j=i}^n \alpha_j D_{ij} \tag{4}$$

Keterangan:

α_i = alfa ke- j

D_{ij} = matriks *hessian*

E_i = *error rate*

$$\delta\alpha_i = \min(\max[\gamma(1 - E_i), \alpha_i], C - \alpha_i) \tag{5}$$

Keterangan:

α_i = alfa ke- i

γ = gamma

E_i = *eror rate*

C = nilai kompleksitass

$$\alpha_i = \alpha_i + \delta\alpha_i \tag{6}$$

α_i = alfa ke- i

$\delta\alpha_i$ = *delta alfa* ke- i

4. Proses perhitungan nilai E_i , $\delta\alpha_i$, dan α_i dilakukan berulang kali hingga mencapai iterasi maksimum.

Langkah terakhir didapatkan nilai *Support Vector* (SV), $SV = \alpha_i > ThresholdSV$, dengan memberikan nilai $ThresholdSV = 0$.

2.4.2. Testing SVM

Tahap awal yang dilakukan yaitu mencari nilai $f(x)$ dengan persamaan 7.

$$f(x) = \sum_{i=1}^m \alpha_i y_i K(x_i, x) + b \tag{7}$$

Keterangan:

α_i = alfa ke- i

y_i =kelas data katih ke- i

m = jumlah data

$K(x_i, x)$ =fungsi kernel yang dipakai

Dengan x = data uji

x_i = data latih ke- i

b = bias

Sedangkan pencarian nilai b (bias) digunakan rumus dalam persamaan 8.

$$b = -\frac{1}{2} [\sum_{i=1}^m \alpha_i y_i K(x_i, x^+) + \sum_{i=1}^m \alpha_i y_i K(x_i, x^-)] \tag{8}$$

Keterangan:

α_i = alfa ke- i

y_i = kelas data katih ke- i

m = jumlah data

$K(x_i, x^+), K(x_i, x^-)$ = fungsi kernel yang dipakai

2.5. One-Againts-All

Multiclass SVM yang dikembangkan berdasarkan sejumlah k , k tersebut merupakan jumlah dari kelas, yaitu merupaka definisi dari pendekatan dengan *one-againts-all* (Sari, 2016). Seperti contoh jika terdapat permasalahan tentang klasifikasi dengan jumlah kelasnya empat buah, kemudiauntu pelatihannya digunakan tiga buah SVM yang ditunjukkan pada Tabel 1.

Tabel 1. *One-Againts-All* dengan empat kelas

	y_i^{-1}	y_i^{-1}	Hipotesis
Kelas 1	Bukan kelas 1		$f^1(x) = (w^1)x + b^1$
Kelas 2	Bukan kelas 2		$f^1(x) = (w^1)x + b^2$
Kelas 3	Bukan kelas 3		$f^1(x) = (w^1)x + b^3$


3. PENGUJIAN DAN ANALISIS

Pada penelitian ini menggunakan metode

support vector machine (SVM) untuk melakukan proses pengujian serta analisis yang dilakukan terhadap sistem cerdas klasifikasi tingkat risiko penyakit gagal ginjal. Pengujian yang dilakukan adalah pengujian parameter λ ($lambda$), pengujian parameter γ ($gamma$), pengujian parameter C ($Complexity$), pengujian parameter σ ($kernel$ RBF), dan pengujian terhadap jumlah iterasi.

3.1. Pengujian λ ($lambda$)

Nilai λ ($lambda$) yang digunakan pada penelitian ini meliputi 0,00001, 0,0001, 0,001,




Gambar 2. Hasil pengujian $lambda$

0,01, 0,1, 0,5, 1, 10, 10, 50, 100. Data yang digunakan dengan Rasio perbandingan data 80%:20% serta parameter yang digunakan γ ($gamma$) = 0,01, C ($Complexity$) = 1, σ kernel RBF = 2, dan iterasi = 10. Hasil pengujian terhadap parameter λ ($Lambda$) ditunjukkan pada Gambar 2.

Hasil analisis pada skenario pengujian nilai λ ($lambda$) pada penelitian ini menunjukkan bahwa nilai λ yang besar akan menyebabkan laju pembelajaran akan berjalan cepat. Tetapi jika terlalu besar akan menyebabkan nilai optimal $lambda$ terlewati serta mencapai nilai konvergen. Sedangkan jika semakin kecil nilai λ ($lambda$) maka akurasi nya semakin turun dikarenakan proses pembelajaran berjalan lambat dan tidak stabil dalam proses pembelajaran.

3.2. Pengujian γ ($gamma$)

Nilai γ ($gamma$) yang digunakan pada penelitian ini meliputi 0,000001, 0,00001, 0,0001, 0,001, 0,01, 0,1, 1, 1,5, 2, 2,5. Data yang digunakan dengan Rasio perbandingan data 80%:20% serta parameter yang digunakan λ ($lambda$) = 1, C ($Complexity$) = 1, σ kernel RBF = 2, dan iterasi = 10. Gambar 3 ialah hasil pengujian terhadap parameter γ ($gamma$).




Gambar 3. Hasil pengujian $gamma$

Nilai $gamma$ berpengaruh pada kecepatan pembelajaran. Yang mana jika semakin tinggi nilai $gamma$ pembelajaran semakin cepat dan mencapai konvergensi. Tetapi jika nilai $gamma$ yang terlalu besar akan menyebabkan nilai akurasi $gamma$ yang optimal terlewati dan akan menyebabkan berkurangnya ketelitian dari sistem, dan sebaliknya jika nilai $gamma$ yang kecil menyebabkan ketelitian dari sistem semakin besar.

3.3. Pengujian C ($Complexity$)

Nilai C ($Complexity$) yang digunakan pada penelitian ini meliputi 0,000001, 0,00001, 0,0001, 0,001, 0,01, 0,1, 1, 10, 20, 40. Data yang digunakan dengan Rasio perbandingan data 80%:20% serta parameter yang digunakan λ ($lambda$) = 1, γ ($gamma$) = 0,0001, σ kernel RBF = 2, dan iterasi = 10. Gambar 4 ialah hasil pengujian terhadap parameter C ($Complexity$) ditunjukkan pada.




Gambar 4. Hasil pengujian $complexity$

Nilai C yang memiliki akurasi paling tinggi berada pada = 0,0001. Parameter ini memiliki pengaruh dalam meminimalkan nilai error pada proses klasifikasi. Hasil analisis dari grafik pada Gambar 4 menunjukkan bahwa nilai C semakin besar akurasi nya tidak stabil dan cenderung menghasilkan akurasi yang kurang baik serta nilai C mengalami kenaikan pada nilai 0,0001 sampai 0,0001. Dari pengujian ini dapat disimpulkan bahwa semakin kecil nilai C memberikan toleransi kesalahan yang kecil dan jika semakin besar nilai C akan memberikan toleransi kesalahan yang besar pada proses

klasifikasi.

3.4. Pengujian Sigma (σ) Kernel RBF

Nilai σ kernel RBF yang digunakan pada penelitian ini meliputi 0,001, 0, 01, 0,1, 1, 1,5, 2, 2,5, 3, 3,5, 4. Data yang digunakan dengan Rasio perbandingan data 80%:20% serta parameter yang digunakan λ (*lambda*) = 1, γ (*gamma*) = 0,0001, C (*Complexity*) = 0,0001 dan iterasi = 10. Hasil pengujian terhadap Nilai σ ditunjukkan pada Gambar 5.




Gambar 5. Hasil pengujian sigma kernel RBF

Rata-rata nilai sigma kernel RBF memiliki akurasi tertinggi sebesar 70,328% pada nilai σ (sigma kecil) = 2. Dari grafik tersebut dapat dilihat bahwa akurasi mengalami kenaikan pada nilai 0,1 dan mengalami penurunan pada nilai 2,5. Sigma memiliki pengaruh pada SVM sebagai parameter kernel RBF yang digunakan, yang mana parameter sigma berpengaruh pada pemetaan data yang terbentuk. Sehingga untuk nilai sigma yang semakin besar maka dapat menghasilkan kernel yang *overfitting*.

3.5. Pengujian Jumlah Iterasi

Pada penelitian ini jumlah iterasi yang digunakan meliputi 50, 60, 70, 80, 90, 100, 200, 300, 400, 500. Data yang digunakan dengan Rasio perbandingan data 80%:20% serta parameter yang digunakan λ (*lambda*) = 1, γ (*gamma*) = 0,0001, σ kernel RBF = 2 dan C (*Complexity*) = 0,0001. Pengujian akurasi ini merupakan pengujian yang paling akhir sehingga digunakan sebagai acuan untuk akurasi sistem secara keseluruhan. Gambar 6 ialah hasil pengujian terhadap jumlah iterasi.



Gambar 6. Hasil pengujian jumlah iterasi

Pengujian pada penelitian ini menghasilkan nilai akurasi yang baik. Semakin besar jumlah iterasi maka akurasi yang didapatkan semakin baik, tetapi terjadi ketidakstabilan tingkat akurasi yaitu pada jumlah iterasi ke 90 dan 100 serta 300 dan 500 mengalami kenaikan sekaligus penurunan. Hal tersebut terjadi karena adanya *overfitting*. *Overfitting* terjadi dimana sebelumnya data yang dipisahkan membentuk hyperplane, yaitu berarti data dekat dengan salah satu classnya. Ketidakstabilan tingkat akurasi juga disebabkan bahwa nilai α_i belum mencapai nilai konvergen, hal tersebut dapat didefinisikan dari tingkat perubahan nilai α_i . Selain itu faktor pemilihan data uji dan data latih yang secara acak pada setiap kali percobaan dapat berpengaruh terhadap akurasi terbaik serta pada metode SVM kurang baik terhadap pemilihan parameter yang digunakan, karena dengan parameter yang tepat dapat dianggap dapat meningkatkan akurasi pada SVM.

4. KESIMPULAN

Berdasarkan hasil yang diperoleh dalam penelitian klasifikasi tingkat risiko pasien gagal ginjal dapat disimpulkan sebagai berikut:

1. Pada data tingkat risiko pasien gagal ginjal, Algoritme *Support Vector Machine* (SVM) dapat diimplementasikan dengan 3 jenis tingkat risiko, yaitu normal, rendah dan tinggi. Penyelesaian dari penelitian ini langkah pertama yaitu pengumpulan data pasien gagal ginjal serta melakukan analisis korelasi untuk masing-masing fitur terhadap tingkat risiko. Langkah selanjutnya menentukan data latih dan data uji sesuai rasio perbandingan data dengan sistem secara acak, kemudian data tersebut dilakukan proses perhitungan normalisasi, kernel RBF dan dilanjutkan dengan perhitungan proses *sequential training* SVM. Setelah di proses akan didapatkan nilai α_i yang merupakan bobot data ke-i dan nilai b (bias) yang nantinya digunakan dalam proses pengujian. Hasil dari pengujian berupa hasil klasifikasi dari masing-masing kelas data uji. Hasil akhir berupa akurasi sistem yang didapat dari membandingkan kelas sebenarnya dengan kelas prediksi hasil dari pengujian sistem.
2. Hasil akurasi dari sistem klasifikasi tingkat risiko pasien gagal ginjal dengan menerapkan algoritme *Support Vector Machine* (SVM) didapatkan akurasi terbaik

sebesar 83,998% dan akurasi tertinggi sebesar 98,33%. Nilai akurasi terbaik didapatkan dari rasio perbandingan data 80%:20%, nilai parameter λ ($lambda$) = 1, γ ($gamma$) = 0,0001, σ kernel RBF = 2, C ($Complexity$) = 0,0001 dan pada jumlah iterasi ke 100.

5. DAFTAR PUSTAKA

- Arifnaldi, M. S., 2014. *Hubungan Kadar Trigliserida dengan Kejadian Stroke Iskemik di RSUD Sukoharjo*. Universitas Muhammadiyah Surakarta. Surakarta.
- Banjarsari, Mutiara Ayu, Budiman, H. Irwan, & Farmadi Andi. 2015. Penerapan K-Optimal pada Algoritma Knn untuk Prediksi Kelulusan Tepat Waktu Mahasiswa Program Studi Ilmu Komputer Fmipa Unlam Berdasarkan IP sampai dengan Semester 4. Volume 2. Kalimantan Selatan.
- Budiarti, R. P. N., 2017. *Klasifikasi Air Sungai Berbasis Kombinasi Teknologi IOT-Big Data Menggunakan SVM*. Institut Teknologi Sepuluh November. Surabaya.
- Butar-butar, A. & Siregar, C. T., 2009. *Karakteristik Pasien dan Kualitas Hidup Pasien Gagal Ginjal Kronik yang Menjalani Terapi Hemodialisa*. Universitas Sumatera Utara. Sumatera Utara.
- Hasanah, U., 2016. *Klasifikasi Kondisi Detak Jantung Berdasarkan Hasil Rekam Elektrokardiografi (Ekg) Menggunakan Algoritma Support Vector Machine (Svm)*. Universitas Brawijaya. Malang.
- Kamal, A., 2014. Estimation of Blood Urea (BUN) Serum Creatinine Level in Patientst of Renal Disorder. *Indian Journal of Fundamental and Applied Life Science*, Volume 4.
- Kompas, 2010. *LIFESTYLE*, [Online] Tersedia di: <<http://lifestyle.kompas.com/read/2010/04/15/08233439/bila.ginjal.menjadi.aus>> [Diakses 21 April 201].
- Kusumadewi, P. S., 2004. *Aplikasi Logika Fuzzy untuk Pendukung Keputusan*. Yogyakarta: Graha Ilmu.
- Larose, D. T., 2005. *Discovering Knowledge In Data, An Introuction to Data Mining*. Canada: John Wiley & sons, inc.
- Lina, N. & Setiyono, A., 2014. Analisis Kebiasaan Makan yang Menyebabkan Peningkatan Kadar Asam Urat. *Jurnal Kesehatan Komunitas Indonesia*, Volume 10.
- Marzuki, A., Sennang, N. & F, F. A., 2014. Gambaran Ureum dan Kreatinin Penderita Malaria di Rumah Sakit Umum Karel Sadsuitubun Langgur. *Jurnal Kesehatan*, Volume 4.
- Munawaroh, B., 2014. Klasifikasi Tingkat Kerusakan Jalan Rel Kereta Api Menggunakan Metode Support Vector Machine (SVM) (Studi Kasus: Jalan Rel 8.16 Malang). Universitas Brawijaya. Malang.
- Normadewi, B., 2012. *Analisis Pengaruh Jenis Kelamin dan Tingkat Pendidikan Terhadap Persepsi Etis Mahasiswa Akuntansi dengan Love of Money Sebagai Variabel Intervening*. Universitas Diponegoro. Semarang.
- Pramoedyo, H., 2013. *Statistika Inferensia Terapan*. Malang: Danar Wijaya.
- Prasetyo, E., 2012. *Data Mining : Konsep dan Aplikasi Menggunakan MATLAB*. Yogyakarta: ANDI.
- Safitri, A. H. & Dewi, D. S. E., 2014. *Deskripsi Tingkat Harapan Pada Penderita Gagal Ginjal Kronik di RSU Prof. DR. Margono Soekarjo Purwokerto*. Universitas Muhammadiyah Purwokerto. Purwokerto.
- Sari, M., 2015. *DosenBiologi.com*. [Online] Tersedia di: <<http://dosenbiologi.com/manusia/bagian-bagian-ginjal>> [Diakses 16 April 2017].
- Silviana, H., Bintanah, S. & Isworo, J. T., 2015. *Hubungan Status Gizi, Asupan Bahan Makan Sumber Purin dengan Kadar Asam Urat pada Pasien Hiperuresemia Rawat Jalan di Rumah Sakit Tugurejo Semarang*. Universitas Muhammadiyah Semarang. Semarang.
- Steel, R. G. & Torrie, J. H., 1989. *Prinsip dan Prosedur Statistika : Suatu Pendekatan Biometrik*. Jakarta: Gramedia Pustaka Umum.
- Suryawan, D. G. A., Arjani, I. A. M. S. & Sudarmanto, I. G., 2016. *Gambaran Kadar Ureum dan Kreatinin Serum Pada Pasien*

Gagal Ginjal Kronis yang Menjalani Terapi Hemodialisis di RSUD Sanjiwani Gianyar. Denpasar.

Susanto, S. & Suryadi, D., 2010. *PENGANTAR DATA MINING Menggali Pengetahuan dari Bongkahan Data.* Yogyakarta: ANDI.

Vijayakumar, S., 1999. Sequential Support Vector Classi. Proc. International Conference on Soft Computing (SOCO'99). pp 610-619.

Warianto, C., 2011. *Gagal Ginjal.*