

STUDI KOMPARASI KLASIFIKASI GAGAL GINJAL KRONIS MENGGUNAKAN ALGORITMA SVM, KNN DAN MLP

Alvi Norma Utami

Jurusan Matematika, FMIPA, Universitas Negeri Surabaya

e-mail : alviutami16030214028@mhs.unesa.ac.id

Abstrak

Gagal ginjal kronis ialah suatu keadaan menurunnya kinerja ginjal yang bersifat kronik, progresif dan bertahan lama. Seseorang dengan gagal ginjal kronis akan memiliki efek samping seperti kerusakan pada sistem saraf serta kerusakan pada kekebalan tubuh dan aktivitas sehari-hari dapat terganggu, oleh karena itu sangat penting untuk mendiagnosis dini agar dapat mengurangi risiko dari dampak gagal ginjal kronis. Pada penelitian ini digunakan algoritma Support Vector Machine, K-Nearest Neighbor dan Multilayer Perceptron sebagai metode pengklasifikasian gagal ginjal kronis. Penelitian ini bertujuan agar dapat menentukan algoritma terbaik dalam klasifikasi gagal ginjal kronis berdasarkan nilai akurasi serta penggunaan waktu pembuatan model. Dataset yang digunakan yaitu dataset *Chronic Kidney Disease* yang bersumber dari UCI Machine Learning repository yang memiliki 2 kelas yaitu kelas gagal ginjal kronis dan kelas bukan gagal ginjal kronis yang diambil dari 400 subyek dengan 24 atribut. Sebelum proses klasifikasi, terlebih dahulu dilakukan normalisasi dan split data menggunakan validasi silang 10-fold. Berdasarkan hasil evaluasi, akurasi tertinggi didapatkan pada saat algoritma MLP dengan nilai rata-rata akurasi mencapai $99.48\% \pm 0.15$. Namun berdasarkan waktu pembuatan model dalam proses klasifikasi, algoritma KNN memiliki waktu yang tercepat yaitu 0.0017 ± 0.0041 detik.

Kata kunci: Gagal ginjal kronis, SVM, KNN, MLP

Abstract

Chronic renal failure is a condition of declining renal performance, progressive and long-lasting. A person with chronic renal failure will have side effects such as damage to the nervous system as well as damage to the immune that can interfere with daily activities, therefore it is very important to diagnose early in order to reduce the risk of the effects of chronic renal failure. In this study used algorithm of Support Vector Machine, K-Nearest Neighbor and Multilayer Perceptron as the method of classifying chronic kidney disease. Research is conducted to determine the best algorithm in classification of chronic renal failure in terms of accuracy and use of time model manufacture. The dataset used is the Chronic Kidney Disease dataset which is sourced from the UCI Machine Learning repository consisting of 2 classes of chronic kidney disease classes and non-chronic kidney disease derived from 400 subjects with 24 attributes. Prior to the classification process, it first performed normalization and split the data using 10-fold cross validation. Based on the results of evaluation, Highest accuracy obtained at the time of the MLP algorithm with an average value of accuracy reached $99.48\% \pm 0.15$. But based on the timing of the model in the classification process, KNN algorithm has the fastest time of 0.0017 ± 0.0041 sec.

Keywords : Chronic Kidney Disease; SVM; KNN; MLP

1. PENDAHULUAN

Ginjal ialah salah satu organ tubuh yang memerankan peranan penting dalam kesehatan, hal ini dikarenakan ginjal memiliki fungsi untuk mengatur keseimbangan cairan tubuh melalui pembuangan sampah sisa metabolisme serta menahan zat-zat yang masih diperlukan dalam tubuh (Sugiarta, Cholissodin, & Santoso, 2019). Apabila ginjal mengalami kerusakan atau terganggu penyakit, maka organ ginjal mengalami penurunan fungsi

kinerja yang akan menyebabkan beberapa masalah dalam tubuh. Salah satu bentuk penyakit ginjal yaitu gagal ginjal kronis. Gagal ginjal kronis ialah suatu keadaan dimana menurunnya kinerja ginjal yang bersifat kronik, progresif dan keberadaannya bertahan lama (Sugiarta, Cholissodin, & Santoso, 2019). Beberapa kondisi seperti diabetes, tekanan darah tinggi serta *life style* yang kurang sehat menjadi penyebabnya. Seseorang dengan gagal ginjal kronis akan memiliki efek samping seperti kerusakan pada sistem saraf

serta kerusakan pada kekebalan tubuh dan aktivitas sehari-hari dapat (Ilham, 2020).

Organisasi kesehatan dunia (WHO) menyatakan bahwa berdasarkan hasil survei tahun 2005 pasien penderita gagal ginjal kronis mencapai sekitar 165 juta, dan akan terus meningkat melebihi 200 juta pada tahun 2025. Sekitar 12 ribu pasien menjalani pengobatan cuci darah dalam jangka waktu seumur hidup, kemudian sekitar 100 ribu pasien menjalani terapi penggantian ginjal serta 600 pasien melakukan transplantasi ginjal (Sugiarta, Cholissodin, & Santoso, 2019). Oleh karena itu, untuk mengontrol dampak dari penyakit gagal ginjal kronis ini, penting dilakukannya diagnosis dini.

Penelitian terdahulu mengenai klasifikasi gagal ginjal kronis seperti pada penelitian (Rubini & Eswaran, 2015) dengan hasil akurasi RBF Network mencapai 98.5%, Multilayer Perceptron (MLP) mencapai 99.75% dan Logistic Regression mencapai 97.5% dan menunjukkan bahwa MLP memiliki akurasi yang lebih tinggi dibandingkan ketiga algoritma tersebut. Penelitian (Amalia, 2018) dalam penggunaan algoritma Support Vector Machine (SVM) dan neural network menunjukkan SVM memiliki akurasi tertinggi yaitu 95.16% dibandingkan dengan akurasi neural network yaitu 93.37%. Serta penelitian (Ariani & Samsuryadi, 2019) dalam pengklasifikasian menggunakan K-Nearest Neighbor (KNN) dengan hasil yang diperoleh sebesar 85.83%. Berdasarkan ketiga penelitian terdahulu tersebut, menunjukkan algoritma SVM, KNN dan MLP memiliki akurasi yang baik, sehingga dalam penelitian ini klasifikasi menggunakan algoritma SVM, KNN dan MLP untuk mengklasifikasi gagal ginjal kronis.

Dataset yang digunakan pada penelitian ini adalah dataset *Chronic Kidney Disease* yang bersumber dari *UCI Machine Learning repository* yang terdiri dari 400 subyek dengan 24 atribut dan 2 kelas yaitu gagal ginjal kronis dan bukan gagal ginjal kronis. Dalam penelitian ini akan dilakukan perbandingan algoritma SVM, KNN dan MLP untuk klasifikasi gagal ginjal kronis. Tujuan dilakukan penelitian ini diharapkan dapat menentukan algoritma terbaik untuk klasifikasi gagal ginjal kronis dan dapat membantu peneliti lain dalam pengklasifikasian gagal ginjal kronis menggunakan algoritma SVM, KNN maupun MLP.

2. KAJIAN TEORI

Gagal Ginjal Kronis

Gagal ginjal kronis ialah suatu keadaan dimana menurunnya kinerja ginjal yang bersifat kronik, progresif

dan berlangsung lama (Sugiarta, Cholissodin, & Santoso, 2019). Beberapa kondisi seperti diabetes, tekanan darah tinggi dan *life style* yang kurang sehat menjadi penyebab gagal ginjal kronis (Ilham, 2020). Pada umumnya, gagal ginjal kronis tidak menimbulkan gejala awal dan mungkin tidak terdeteksi sebelum kehilangan 25% fungsinya (Polat, Mehr, & Cetin, 2017). Seseorang yang menderita gagal ginjal kronis akan memiliki efek samping seperti kerusakan pada sistem saraf serta kerusakan pada kekebalan tubuh dan aktivitas sehari-hari dapat terganggu (Ilham, 2020). Beberapa gejala yang mungkin timbul jika sudah semakin parah yaitu kaki membengkak, lemas, pucat, hilangnya nafsu makan, mual, gatal-gatal, kram otot, sulit tidur dan sesak napas (alodokter.com, 2020). Pengobatan terakhir setelah berbagai pengobatan lainnya untuk seseorang yang menderita tahap akhir gagal ginjal kronis yaitu menjalani cuci darah atau transplantasi ginjal (Polat, Mehr, & Cetin, 2017).

Support Vector Machine

Support Vector Machine (SVM) merupakan metode klasifikasi dengan diterapkannya teori pembelajaran statistika yang memiliki kinerja klasifikasi yang baik, adanya pemetaan data asli ke dimensi yang lebih tinggi menggunakan teknik kernel, secara umum dilakukan pemisahan dua kelas dan mencari cara dalam menemukan *hyperplane* terbaik (Wijayanti, Furqon, & Adinugroho, 2018).

Pengklasifikasian algoritma SVM dilakukan dengan menemukan *hyperplane* optimal yang memiliki fungsi menjadi pemisah data antar kelas. Representasi jarak antara kelas satu dengan kelas lainnya memiliki nilai yang disebut nilai margin. maksimum nilai margin ini lah yang menentukan optimalnya *hyperplane*. *Support vector* adalah titik pada tiap-tiap kelas yang mempunyai jarak terdekat dari *hyperplane* (Laksono & Imah, M.Kom., 2019).

Diberikan dataset dengan dua kelas, $x_i \in R^n, n > 1, i = 1, 2, \dots, l$ dan $y_i \in \{-1, +1\}$ dengan $g(x) = \langle w, x \rangle + c$ merupakan *hyperplane*, maka *decision rule* didefinisikan dalam persamaan (1).

$$f(x) = \begin{cases} +1, & g(x) \geq 1 \\ -1, & g(x) < 1 \end{cases} \quad (1)$$

kemudian perlu dilakukan meminimalkan nilai pada persamaan (2) untuk menemukan *hyperplane*.

$$\frac{1}{2} \|w\|^2 = \frac{1}{2} (w_1^2 + w_2^2) \quad (2)$$

dengan syarat :

$$(w_1 \cdot x_i + w_2 \cdot x_i + c) \geq 1 \quad (3)$$

lalu apabila didapatkan *hyperplane* yang optimal, dilakukan perhitungan fungsi keputusan $sign(f(x))$ dalam penentuan kelas data.

$$f(x_d) = \sum_{i=1}^m a_i y_i K(x_i, x) + y \quad (4)$$

m adalah jumlah *support vector*, a_i adalah bobot pada tiap-tiap data, dan $K(x_i, x)$ adalah fungsi kernel (Laksono & Imah, M.Kom., 2019).

K-Nearest Neighbor

Pada tahun 1951, Fix dan Hodges memperkenalkan metode yaitu K-Nearest Neighbor (KNN) dan telah banyak digunakan pada klasifikasi dan pengenalan pola (Ariani & Samsuryadi, 2019). KNN merupakan algoritma sederhana dengan menyimpan semua kondisi dan mengklasifikasikan kedalam kondisi baru berdasarkan kemiripan nilai (Sugiarta, Cholissodin, & Santoso, 2019). Pengklasifikasian KNN sangat bergantung pada nilai k sebagai penentu jarak terdekat yang diambil. Beberapa kelebihan dari KNN seperti memiliki ketahanan dalam mengolah dataset yang besar, mudah implementasinya dan membutuhkan waktu pelatihan yang dibutuhkan sangat singkat (Yunus, 2018).

Pada umumnya langkah-langkah pengklasifikasian menggunakan algoritma KNN adalah nilai parameter k ditentukan, kemudian diantara data uji dan data latih akan dihitung jaraknya, lalu jarak akan diurutkan, kemudian jarak terdekat sampai urutan k akan ditentukan, lalu kelas yang sesuai akan dipasangkan. Setelah itu, menentukan jumlah kelas dari tetangga yang terdekat serta akan ditetapkan kelas tersebut sebagai kelas data yang diuji. Penghitungan jarak dapat menggunakan *Euclidean distance* seperti pada persamaan (5).

$$\text{dist}(x_{1i}, x_{2i}) = \sqrt{\sum_{i=1}^n (x_{1i} - x_{2i})^2} \quad (5)$$

dimana n merupakan dimensi data, x_{1i} merupakan data latih, x_{2i} merupakan data uji dengan $i = 1, 2, \dots, n$ (Ariani & Samsuryadi, 2019).

Multilayer Perceptron

Multilayer Perceptron (MLP) ialah model jaringan syaraf tiruan *feed forward*. MLP memiliki struktur dari tiga lapisan berbeda yaitu lapisan masukan, lapisan tersembunyi dan lapisan keluaran. Lapisan masukan meneruskan sejumlah unit atau neuron kepada lapisan tersembunyi. MLP dapat mempunyai lebih dari satu lapisan tersembunyi. Lapisan tersembunyi menggunakan fungsi aktivasi untuk meneruskan ke lapisan keluaran. MLP dikatakan sebagai jaringan pemrosesan terdistribusi dikarebakan efek dari unit tersembunyi yang dapat didistribusikan ke seluruh ruang input. Metode ini telah banyak dan berhasil di aplikasikan kepada bidang seperti keuangan, kedokteran, teknik, biologi dan pertanian (Rubini & Eswaran, 2015).

Perhitungan keluaran setiap unit pada jaringan dilakukan dengan cara menghitung unit lapisan tersembunyi dengan menjumlahkan bobot yang berasal dari input dengan menggunakan persamaan (6) (Aljarah, Faris, & Mirjalili, 2016).

$$S_j = \sum_{i=1}^n w_{ij} I_i + \beta_j \quad (6)$$

I_i merupakan variabel input i , dan w_{ij} merupakan bobot yang terhubung antara I_i dengan unit tersembunyi j . kemudian dilakukan perhitungan dengan fungsi aktivasi berdasarkan nilai fungsi penjumlahan. Menggunakan fungsi aktivasi sigmoid yang banyak di terapkan di literatur, keluaran dari unit tersembunyi j dapat dihitung menggunakan persamaan (7).

$$f_j(x) = \frac{1}{1+e^{-S_j}} \quad (7)$$

setelah itu, perhitungan keluaran akhir dari jaringan dilakukan dengan persamaan (8).

$$\hat{y}_k = \sum_{i=1}^m W_{ki} f_i + \beta_k \quad (8)$$

3. METODE

Pada bagian ini terdapat tiga tahap yaitu pra-pemrosesan data, proses klasifikasi dan proses evaluasi hasil klasifikasi.

Pra-pemrosesan data

Tahap pra-pemrosesan data memiliki tujuan untuk menyiapkan *input* data agar sesuai dengan algoritma klasifikasi yang digunakan. Pada tahap ini, dilakukannya normalisasi dan *split data*. Normalisasi bertujuan agar data memiliki rentang yang sama. Normalisasi pada penelitian ini menggunakan normalisasi *min-max* yang akan menormalisasi data dengan rentang $[0,1]$. Sebelum melakukan klasifikasi dibutuhkan *split data*. *Split data* merupakan pembagian data menjadi data latih dan data uji sesuai dengan ukuran yang ditentukan. Dalam penelitian ini, digunakan validasi silang k -fold dengan nilai k yaitu 10. Validasi silang k -fold adalah metode dengan penggunaan data keseluruhan menjadi data latih dan data uji dari masing-masing k partisi U_1, U_2, \dots, U_k , data keseluruhan akan dipartisi sebanyak partisi yang mempunyai jumlah sama. Setelah itu, sebanyak k iterasi dilakukannya proses pengujian serta pelatihan. Sehingga iterasi ke- i partisi U_i merupakan data uji dan sisanya merupakan data latih (Wulandari & Juniati, 2017).

Proses Klasifikasi

Proses klasifikasi dalam penelitian ini menggunakan algoritma SVM dengan beberapa parameter yaitu C , epsilon, γ dan fungsi kernel. Parameter C menyatakan nilai batas ambang dan level akurasi dari fungsi aproksimasi

yang mempunyai pengaruh terhadap pemakaian *support vector* merupakan kegunaan parameter epsilon. Algoritma SVM dengan polykernel berderajat satu dan dua menggunakan parameter C sebesar 1, 3 dan 6 serta epsilon (ϵ) dengan nilai 10^{-3} , 10^{-6} dan 10^{-12} . Sedangkan untuk algoritma SVM dengan kernel Radial Basis Function (RBF) menggunakan parameter C sebesar 1, 3 dan 6, epsilon (ϵ) dengan nilai 10^{-3} , 10^{-6} dan 10^{-12} serta gamma (γ) dengan nilai 0.5 dan 0.01. Pada proses klasifikasi dengan algoritma MLP menggunakan dua parameter yaitu learning rate dan momentum. Parameter learning rate yang digunakan bernilai 0.3, 0.6 dan 0.9. sedangkan parameter momentum yang digunakan bernilai 0.2, 0.4 dan 0.8. Pada proses klasifikasi dengan algoritma KNN menggunakan parameter k sebesar 1 hingga 6.

Proses Evaluasi Hasil Klasifikasi

Pada penelitian ini penggunaan *confusion matrix* sebagai alat ukur performa algoritma dengan dilakukannya perbandingan antara hasil klasifikasi sesuai data yang sesungguhnya terhadap jumlah keseluruhan data. Dari *confusion matrix* dapat mengetahui jumlah data dari tiap-tiap kelas dan prediksi akurasi dengan dilakukan perhitungan menggunakan persamaan (9).

$$\text{Akurasi} = \frac{TP+TN}{TP+TN+FP+FN} \quad (9)$$

dimana TP (*True Positive*) ialah jumlah data kelas gagal ginjal kronis yang terklasifikasi dengan benar pada kelas gagal ginjal kronis, FP (*False Positive*) ialah jumlah data kelas bukan gagal ginjal kronis yang terklasifikasi dengan benar pada kelas gagal ginjal kronis, FN (*False Negative*) ialah jumlah data kelas gagal ginjal kronis yang terklasifikasi dengan benar pada kelas bukan gagal ginjal kronis dan TN (*True Negative*) ialah jumlah data kelas bukan gagal ginjal kronis yang terklasifikasi dengan benar pada kelas bukan gagal ginjal kronis.

Precision merupakan tingkat keakuratan informasi yang diinginkan terhadap prediksi yang dihasilkan dari sistem (Laksono & Imah, M.Kom., 2019). *Precision* dihitung menggunakan persamaan (10).

$$\text{Precision} = \frac{TP}{TP+FP} \quad (10)$$

Recall merupakan tingkat keberhasilan sistem dalam mengklasifikasikan data dengan benar (Laksono & Imah, M.Kom., 2019). *Recall* dihitung menggunakan persamaan (11).

$$\text{Recall} = \frac{TP}{TP+FN} \quad (11)$$

F-measure merupakan penghitungan evaluasi pengklasifikasian algoritma dari *precision* dan *recall*

(Laksono & Imah, M.Kom., 2019). *F-measure* dihitung menggunakan persamaan (12).

$$F - \text{Measure} = 2 \cdot \frac{\text{Precision} \cdot \text{Recall}}{\text{Precision} + \text{Recall}} \quad (12)$$

4. DATASET

Dataset yang digunakan pada penelitian ini yaitu dataset *Chronic Kidney Disease* yang bersumber dari UCI Machine Learning repository (UCI Machine Learning Repository, 2015) dan terdiri dari 400 subyek dengan 24 atribut serta 2 kelas yaitu gagal ginjal kronis dan non gagal ginjal kronis. 24 atribut pada dataset ini meliputi usia, tekanan darah, *specific gravity*, albumin, gula, sel darah merah, *pus cell*, *pus cell clumps*, bakteri, glukosa darah acak, urea darah, kreatinin serum, sodium, potassium, hemoglobin, *packed cell volume*, jumlah sel darah putih, jumlah sel darah merah, hipertensi, diabetes mellitus, penyakit arteri coroner, nafsu makan, pedal edema dan anemia.

5. HASIL DAN PEMBAHASAN

Pada penelitian ini dilakukan uji coba dataset pada masing-masing algoritma dengan beberapa parameter. Hasil rata-rata akurasi, *precision*, *recall* dan *F-measure* dari setiap parameter dengan menggunakan algoritma SVM, KNN dan MLP ditunjukkan pada Tabel 1.

Tabel 1. Tabel Hasil Percobaan Algoritma

Algoritma	Nilai Rata-Rata Akurasi (%)	Nilai Rata-Rata Precision	Nilai Rata-Rata Recall	Nilai Rata-Rata F-measure
SVM Linier	98.03 ± 0.54	0.95 ± 0.01	1 ± 0	0.97 ± 0.01
SVM Poly Kernel	98.89 ± 0.49	0.98 ± 0.01	0.99 ± 0.01	0.99 ± 0.01
SVM Kernel RBF	97.51 ± 1.57	0.94 ± 0.03	1 ± 0	0.97 ± 0.02
KNN	94.92 ± 0.97	0.88 ± 0.02	1 ± 0	0.94 ± 0.01
MLP	99.48 ± 0.15	0.99 ± 0.003	1 ± 0	0.99 ± 0.002

Tabel 1. Menunjukkan bahwa nilai rata-rata akurasi algoritma SVM linier mencapai 98.03%, dengan nilai *precision* sejumlah 0.95, *recall* sejumlah 1 dan *f-measure* sejumlah 0.97. Pada algoritma SVM poly kernel berderajat dua, nilai rata-rata akurasi mencapai 98.89% dengan *precision* sejumlah 0.98, *recall* sejumlah 0.99 dan *f-*

measure sejumlah 0.99. Pada algoritma SVM dengan kernel RBF, nilai rata-rata akurasi mencapai 97.51% dengan *precision* sejumlah 0.94, *recall* sejumlah 1 dan *f-measure* sejumlah 0.97. Pada algoritma KNN, nilai rata-rata akurasi mencapai 94.92% dengan *precision* sejumlah 0.88, *recall* sejumlah 1 dan *f-measure* sejumlah 0.94. Pada algoritma MLP memiliki nilai rata-rata akurasi mencapai 99.48% dengan nilai *precision* sejumlah 0.99, *recall* sejumlah 1 dan *f-measure* sejumlah 0.99.

Pada penelitian ini, akurasi terbaik dalam klasifikasi gagal ginjal kronis menggunakan algoritma SVM, KNN dan MLP dicapai saat penggunaan algoritma MLP dengan nilai rata-rata akurasi sebesar 99.48%. Sedangkan akurasi terendah dicapai saat menggunakan algoritma KNN dengan nilai rata-rata akurasi sebesar 94.92%.



Gambar 1. Waktu Pembuatan Model Algoritma Klasifikasi

Waktu yang diperlukan untuk pembuatan model klasifikasi masing-masing algoritma ditunjukkan pada Gambar 1. Diketahui bahwa pada algoritma SVM linier membutuhkan rata-rata waktu untuk pembuatan model selama 0.0222 ± 0.0264 detik. Algoritma SVM polykernel berderajat dua membutuhkan rata-rata waktu selama 0.0167 ± 0.0112 detik. Algoritma SVM kernel RBF membutuhkan rata-rata waktu selama 0.0333 ± 0.0153 detik. Algoritma KNN membutuhkan rata-rata waktu selama 0.0017 ± 0.0041 detik. Sedangkan algoritma MLP membutuhkan rata-rata waktu selama 3.5 ± 0.0377 detik. Berdasarkan gambar 1. Waktu tercepat dicapai pada saat algoritma KNN. Sedangkan waktu terlama dicapai pada saat algoritma MLP.

Hasil klasifikasi gagal ginjal kronis menggunakan algoritma SVM, KNN dan MLP menyatakan akurasi terbaik didapatkan pada saat penggunaan algoritma MLP. Sedangkan akurasi terendah didapatkan pada saat algoritma KNN. Namun berdasarkan waktu yang digunakan untuk membuat model dalam proses klasifikasi algoritma, algoritma KNN jauh lebih unggul dikarenakan

KNN menjadi algoritma dengan waktu tercepat, hal ini sesuai dengan penelitian (Yunus, 2018) yang mengatakan bahwa salah satu kelebihan KNN yaitu membutuhkan waktu yang singkat dalam pembuatan model. Algoritma SVM memiliki kemampuan klasifikasi yang cukup baik, berdasarkan hasil rata-rata akurasi yang lebih tinggi dibandingkan algoritma KNN yang merupakan akurasi terendah dan juga waktu pembuatan model yang lebih baik dibandingkan MLP yang memiliki waktu pembuatan model terlama.

6. KESIMPULAN

Pada penelitian ini, dilakukan klasifikasi gagal ginjal kronis menggunakan algoritma Support Vector Machine (SVM), K-Nearest Neighbor (KNN) dan Multilayer Perceptron (MLP). Parameter yang digunakan pada algoritma SVM dengan polykernel berderajat satu dan dua yaitu C sebesar 1, 3 dan 6 serta epsilon dengan nilai 10^{-3} , 10^{-6} dan 10^{-12} . Sedangkan untuk algoritma SVM menggunakan kernel Radial Basis Function (RBF) dengan parameter C sebesar 1, 3 dan 6, epsilon dengan nilai 10^{-3} , 10^{-6} dan 10^{-12} serta gamma dengan nilai 0.5 dan 0.01. Parameter yang digunakan pada algoritma MLP learning rate 0.3, 0.6 dan 0.9 dan momentum 0.2, 0.4 dan 0.8. Parameter yang digunakan algoritma KNN yaitu parameter k dengan nilai 1 hingga 6.

Berdasarkan hasil klasifikasi gagal ginjal kronis menggunakan algoritma SVM, KNN dan MLP menunjukkan bahwa akurasi tertinggi didapatkan pada saat algoritma MLP dengan nilai rata-rata akurasi mencapai $99.48\% \pm 0.15$. Sedangkan akurasi terendah didapatkan pada saat algoritma KNN dengan nilai rata-rata akurasi mencapai 94.92 ± 0.97 . Namun berdasarkan segi waktu pembuatan model, algoritma KNN memiliki waktu yang tercepat yaitu 0.0017 ± 0.0041 detik. Sedangkan waktu terlama dicapai pada saat algoritma MLP yaitu 3.5 ± 0.0377 detik

DAFTAR PUSTAKA

- Aljarah, I., Faris, H., & Mirjalili, S. (2016). Optimizing Connection Weights in Neural Network Using the Whale Optimization Algorithm. *Soft Comput.*
- alodokter.com. (2020). Retrieved from alodokter.com: <https://www.alodokter.com/macam-macam-penyakit-ginjal-yang-perlu-diwaspadai>
- Ariani, A., & Samsuryadi. (2019). Klasifikasi Penyakit Ginjal Kronis Menggunakan K-Nearest Neighbor. *Prosiding Annual Research Seminar*, (pp. 148-151).

**STUDI KOMPARASI KLASIFIKASI GAGAL GINJAL KRONIS MENGGUNAKAN ALGORITMA SVM,
KNN DAN MLP**

- Ilham, A. (2020). Hybrid Metode Bootstrap dan Teknik Imputasi Pada Metode C4-5 untuk Prediksi Penyakit Ginjal Kronis. *Statistika, Vol. 8, No. 1*.
- Kurnianto, E. A., Cholissodin, I., & Santoso, E. (2018). Klasifikasi Penderita Penyakit Ginjal Kronis Menggunakan Algoritma Support Vector Machine (SVM). *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer, Vol. 2, No. 12*, 6597-6602.
- Laksono, I., & Imah, M.Kom., D. (2019). Klasifikasi Schizophrenia Berdasarkan Sinyal EEG Menggunakan Algoritma Support Vector Machine. *MATHUNESA : Jurnal Ilmiah Matematika, Volume 7 No. 2*.
- Polat, H., Mehr, H. D., & Cetin, A. (2017). Diagnosis of Chronic Kidney Disease Based on Support Vector Machine by Feature Selection Methods. *J Med Syst*, 41-55.
- Rubini, L., & Eswaran, D. (2015). Generating Comparative Analysis of Early Stage Prediction of Chronic Kidney Disease. *Jurnal Of Modern Engineering Research (IJMER), Vol. 5, Iss. 7*.
- Sugiarta, K. A., Cholissodin, I., & Santoso, E. (2019). Optimasi K-Nearest Neighbor Menggunakan Bat Algoritma Untuk Klasifikasi Penyakit Ginjal Kronis. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer, Vol. 3, No.10*, 10301-10308.
- UCI Machine Learning Repository. (2015, Juli). Retrieved from UCI Machine Learning Repository: http://archive.ics.uci.edu/ml/datasets/Chronic_Kidney_Disease#
- Wijayanti, R. A., Furqon, M., & Adinugroho, S. (2018). Penerapan Algoritma Support Vector Machine Terhadap Klasifikasi Tingkat Risiko Pasien Gagal Ginjal. *Jurnal Pengembangan Teknologi Informasi dan Ilmu Komputer, Vol. 2, No. 10*, 3500-3507.
- Wulandari, I., & Juniati, D. (2017). Penerapan Dimensi Fraktal Untuk Klasifikasi Laras Pada Musik Gamelan. *Jurnal Ilmiah Matematika, Volume 3 No. 6*.