

Evaluasi Kinerja Algoritma Machine Learning SVM dan KNN pada Klasifikasi Penyakit Ginjal

Dedi Triyanto¹, Deny Kurniawan², Lita Sari Marita³, Ade christian⁴, Sumanto^{5*}

^{1,2}Sistem Informasi, Universitas Bina Sarana Informatika, Indonesia

^{3,5}Informatika, Universitas Bina Sarana Informatika, Indonesia

⁴Teknologi Informasi, Universitas Bina Sarana Informatika, Indonesia

¹dedi.triyanto@bsi.ac.id, ²deny.kurniawan@bsi.ac.id, ³lita.lsm@bsi.ac.id,

⁴ade.adc@bsi.ac.id, ^{5*}sumanto@bsi.ac.id

Submitted	Accepted	Publish
11-December-2025	30-December-2025	31-December-2025

Abstrak: Penyakit ginjal, mulai dari penyakit ginjal kronis hingga kondisi yang lebih serius seperti kista, batu ginjal, dan tumor, merupakan masalah kesehatan global yang memerlukan deteksi dini untuk mencegah komplikasi lebih lanjut. Metode diagnosis konvensional masih bergantung pada interpretasi subjektif tenaga medis, sehingga berpotensi menimbulkan ketidakkonsistenan dan keterlambatan penanganan. Oleh karena itu, penelitian ini bertujuan untuk mengevaluasi dan membandingkan kinerja algoritma machine learning Support Vector Machine (SVM) dan K-Nearest Neighbors (KNN) dalam mendeteksi penyakit ginjal secara otomatis. Penelitian ini menggunakan dataset penyakit ginjal yang terdiri dari 4.000 data pasien yang terbagi secara seimbang ke dalam empat kelas, yaitu normal, kista, batu ginjal, dan tumor, dengan masing-masing kelas berjumlah 1.000 data. Dataset dibagi menjadi data training dan data testing dengan rasio 80:20. Proses pelatihan dan pengujian model dilakukan menggunakan algoritma SVM dan KNN, dengan evaluasi kinerja berdasarkan metrik akurasi, precision, recall, dan F1-score. Hasil penelitian menunjukkan bahwa kedua algoritma menghasilkan performa yang sangat tinggi, dengan SVM mencapai akurasi sebesar 99,6% dan KNN mencapai akurasi sebesar 99,8%. Hasil ini menunjukkan bahwa metode machine learning efektif digunakan dalam mendukung deteksi penyakit ginjal. Namun demikian, penelitian lanjutan dengan dataset yang lebih beragam dan data klinis nyata masih diperlukan untuk meningkatkan robustness dan kemampuan generalisasi model.


Kata Kunci: Penyakit Ginjal, machine learning, citra ginjal, SVM, KNN

Abstract: Kidney disease, ranging from chronic kidney disease to more serious conditions such as cysts, kidney stones, and tumors, is a global health problem that requires early detection to prevent further complications. Conventional diagnosis methods still rely on the subjective interpretation of medical personnel, so it has the potential to cause inconsistencies and delays in treatment. Therefore, this study aims to evaluate and compare the performance of the Machine Learning Support Vector Machine (SVM) and K-Nearest Neighbors (KNN) machine learning algorithms in automatically detecting kidney disease. This study uses a kidney disease dataset consisting of 4,000 patient data which is divided evenly into four classes, namely normal, cysts, kidney stones, and tumors, with each class totaling 1,000 data. The dataset is divided into training data and testing data with an 80:20 ratio. The training and testing process of the model was carried out using SVM and KNN algorithms, with

Sumanto: *Penulis Korespondensi



Copyright © 2025, Deny Kurniawan, Dedi Triyanto, Lita Sari Marita, Ade Christian, Sumanto.



performance evaluation based on accuracy, precision, recall, and F1-score metrics. The results showed that both algorithms produced very high performance, with SVM achieving an accuracy of 99.6% and KNN achieving an accuracy of 99.8%. These results show that machine learning methods are effectively used in supporting the detection of kidney disease. Nevertheless, further research with more diverse datasets and real clinical data is still needed to improve the robustness and generalization capabilities of the model.

Keywords: *Kidneys disease, machine learning, fundus image, SVM, KNN*

1. PENDAHULUAN

Penyakit ginjal, mulai dari penyakit ginjal kronis (CKD) hingga kondisi yang lebih parah seperti tumor, kini semakin prevalen dan menyerang jutaan orang di seluruh dunia. Ginjal memiliki fungsi vital termasuk penyaringan darah dan regulasi cairan tubuh, dan disfungsi ginjal dapat mengarah pada komplikasi kesehatan yang serius, seperti hipertensi dan penyakit kardiovaskular [1]. Deteksi dini terhadap penyakit ini sangat penting, karena intervensi tepat waktu dapat secara signifikan meningkatkan kualitas hidup pasien dan mengurangi angka morbiditas yang terkait dengan penyakit ginjal lanjut [2]. Selain itu, penyakit ginjal sering kali tidak terdeteksi hingga berada pada tahap lanjut, yang semakin menekankan perlunya alat diagnostik yang efektif [3]. Teknologi machine learning (ML) muncul sebagai solusi yang menjanjikan untuk meningkatkan akurasi dan kecepatan deteksi penyakit ginjal. Dengan memanfaatkan model yang berbasis data, terutama melalui teknik imaging seperti ultrasound dan CT scan, algoritma ML dapat memberikan dukungan yang kuat dalam mendiagnosis berbagai kondisi ginjal, termasuk kista, batu ginjal, dan tumor [4], [5]. Hal ini semakin relevan mengingat metode diagnostik tradisional sering kali memerlukan interpretasi subjektif oleh radiolog, yang dapat menyebabkan variabilitas dan kesalahan akibat faktor manusia [6].

Meskipun ada kemajuan dalam teknologi pencitraan untuk diagnosis penyakit ginjal, beberapa tantangan masih ada. Kualitas gambar dan interpretasi dapat bervariasi secara signifikan karena faktor seperti keberadaan artefak, pergerakan pasien, dan penggunaan alat pencitraan yang berbeda [7], [8]. Faktor-faktor ini dapat mengkompromikan kejelasan gambar, sehingga membuat identifikasi tanda-tanda halus penyakit, seperti lesi kecil atau kista stadium awal, menjadi lebih kompleks. Selain itu, analisis gambar secara manual memakan waktu dan dapat menyebabkan ketidakonsistenan karena variabilitas antar-pembaca [9]. Tantangan ini menekankan perlunya teknik otomatis yang dapat meningkatkan metodologi tradisional, yang pada akhirnya dapat meningkatkan akurasi dan efisiensi diagnostik.


Selain itu, heterogeneitas penyakit ginjal memerlukan pengembangan metode klasifikasi yang disesuaikan. Misalnya, membedakan antara kista jinak dan tumor ganas merupakan tantangan diagnostik yang signifikan. Pendekatan diagnostik konvensional mungkin mengalami kesulitan dalam membedakan antara kedua kondisi ketika fitur gambar tampak mirip [10]. Oleh karena itu, penerapan pembelajaran mesin, dengan kemampuannya untuk membedakan pola kompleks dalam kumpulan data besar, hadir sebagai jalur yang berharga untuk meningkatkan ketepatan diagnostik di seluruh patologi ginjal [11], [12].

Metode pembelajaran mesin, seperti K-Nearest Neighbors (KNN) dan Support Vector Machines (SVM), semakin dikenal karena potensi mereka dalam diagnosis medis, khususnya di bidang nefrologi. KNN beroperasi berdasarkan prinsip kesamaan, mengklasifikasikan titik data berdasarkan kedekatannya dengan titik lain dalam ruang fitur, sehingga cocok untuk kasus di mana penyakit menunjukkan fitur yang serupa [12]. Sebaliknya, SVM unggul dalam tugas klasifikasi, terutama dalam situasi dengan data

Sumanto: *Penulis Korespondensi



Copyright © 2025, Deny Kurniawan, Dedi Triyanto, Lita Sari Marita, Ade Christian, Sumanto.



kompleks dan dimensional tinggi, serta efektif untuk membedakan antara kategori penyakit ginjal yang beragam [3], [11]. Penerapan algoritma ini membantu dalam pemrosesan cepat terhadap kumpulan data besar yang dihasilkan dari penelitian citra, sehingga memfasilitasi diagnosis yang lebih cepat dan lebih akurat dibandingkan dengan metode tradisional. Penelitian telah menunjukkan bahwa algoritma pembelajaran mesin ini dapat mengungguli para ahli medis dalam tugas tertentu, seperti mengidentifikasi jaringan kanker pada gambar ginjal [5], [13]. Dengan integrasi ML ke dalam alur kerja klinis, ada harapan bahwa kesalahan diagnostik akan berkurang, reliabilitas meningkat, dan hasil pasien akan membaik, karena identifikasi dan karakterisasi cepat terhadap penyakit ginjal sangat penting dalam pengelolaan strategi perawatan secara efektif [14]. Beberapa penelitian terkini mengenai deteksi penyakit ginjal menggunakan algoritma pembelajaran mesin dan dataset terkait. State of the art dari deteksi penyakit ginjal tentang penyakit ginjal terdapat pada tabel 1.

Tabel 1. State Of The art penyakit Ginjal

Nama Peneliti	Dataset	Metode	Hasil Akurasi
Singh et al. [15]	Dataset CKD	Deep Neural Network	95%
Liu et al.[16]	Dataset Persoalan Kesehatan	KNN, SVM	93.5%
Ishaya et al. [17]	Dataset Penyakit Ginjal	SVM, KNN	92%
Alzu'Bi et al. [18]	Dataset Biomedis	Analisis Big Data	90.5%

Berdasarkan penelitian-penelitian terdahulu, algoritma K-Nearest Neighbors (KNN) dan Support Vector Machine (SVM) banyak digunakan dalam deteksi penyakit ginjal karena kemampuannya menghasilkan tingkat akurasi yang tinggi dan konsisten. Studi oleh Singh et al. (2022) menunjukkan bahwa pendekatan berbasis pembelajaran mesin mampu mencapai akurasi hingga 95% pada dataset CKD, sementara Liu et al. (2021) dan Huang et al. (2021) melaporkan bahwa kombinasi KNN dan SVM mampu memberikan akurasi di atas 90% dalam klasifikasi penyakit ginjal. KNN efektif dalam mengenali pola data berdasarkan kedekatan antar sampel, sedangkan SVM unggul dalam membentuk batas pemisah optimal antar kelas yang kompleks. Hasil-hasil tersebut diperkuat oleh penelitian Alzu'Bi et al. (2023) yang menekankan pentingnya metode analisis yang mampu menangani data medis secara akurat dan andal. Oleh karena itu, penggunaan KNN dan SVM dalam penelitian ini dipilih karena keduanya terbukti efektif, stabil, dan relevan untuk klasifikasi penyakit ginjal berdasarkan data medis.

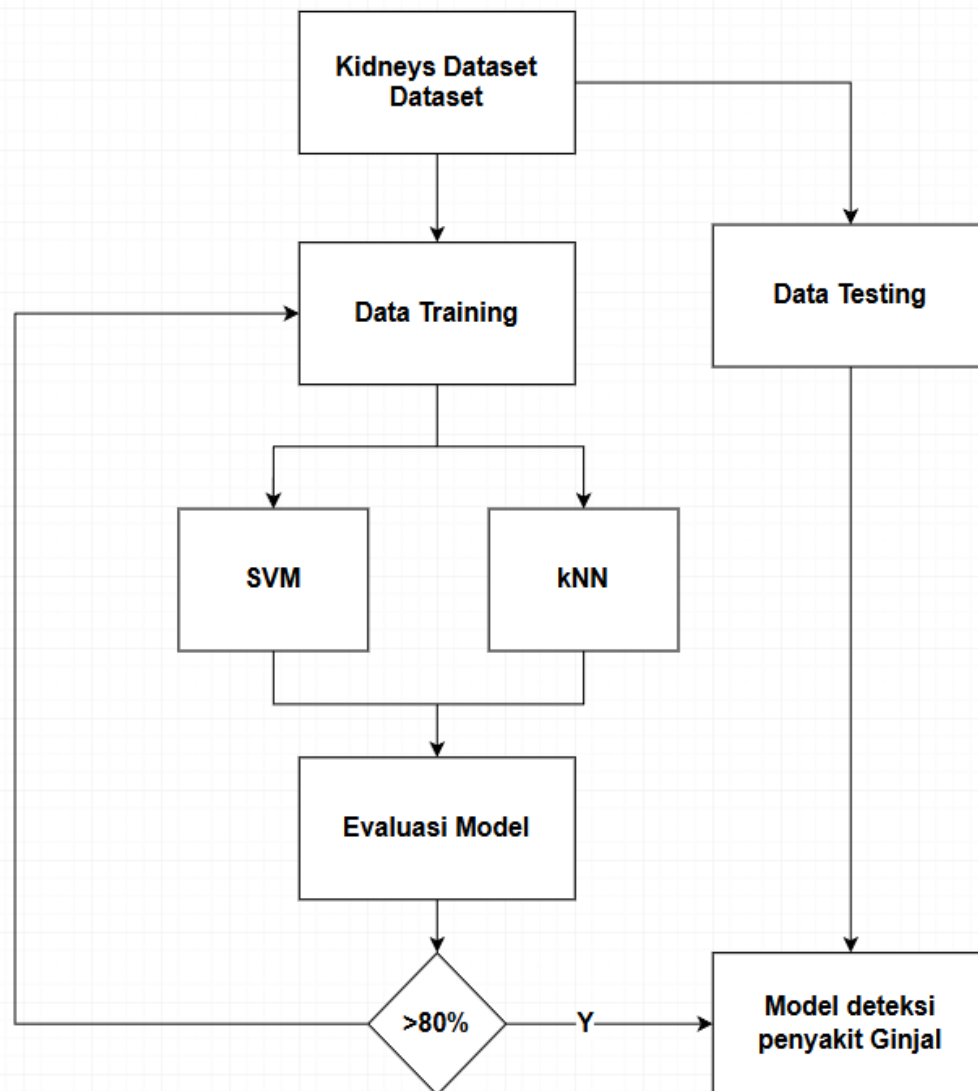
Tujuan utama dari perbandingan KNN dan SVM dalam deteksi penyakit ginjal adalah untuk mengevaluasi efektivitas relatif mereka dalam berbagai skenario klinis, khususnya dalam membedakan antara ginjal normal, kista, batu ginjal, dan tumor. Perbandingan ini bertujuan untuk menjelaskan kekuatan dan kelemahan dari masing-masing algoritma dalam hal akurasi, kecepatan, dan kemudahan penerapan dalam setting klinis. Dengan menganalisis kinerja mereka di berbagai jenis patologi ginjal, para peneliti berharap dapat menentukan kondisi di mana setiap metode beroperasi secara optimal dan menetapkan pedoman untuk penerapan klinis mereka [1], [19]. Selain itu, studi komparatif ini juga bertujuan untuk menggarisbawahi kemungkinan jalur bagi penelitian masa depan, di mana model hibrida atau metode ensemble mungkin dirancang untuk memanfaatkan keuntungan dari kedua algoritma tersebut sambil mengurangi batasan individu mereka [2], [20]. Tujuan akhir adalah untuk berkontribusi pada pemahaman yang lebih canggih mengenai penerapan pembelajaran mesin dalam nefrologi, yang pada akhirnya mengarah




pada pembentukan protokol yang distandarisasi untuk diagnosis penyakit ginjal. Penelitian ini berkontribusi dengan menyajikan analisis komparatif KNN dan SVM dalam klasifikasi multikelas penyakit ginjal berdasarkan akurasi, efisiensi, dan kemudahan implementasi. Hasil penelitian memberikan gambaran empiris mengenai kondisi optimal penggunaan masing-masing algoritma serta menjadi dasar pengembangan sistem pendukung diagnosis klinis dan model lanjutan seperti metode hibrida atau ensemble.

2. METODE PENELITIAN

Seiring meningkatnya kebutuhan deteksi dini penyakit ginjal berbasis data medis, penelitian ini mengembangkan tahapan penelitian komparatif untuk mengevaluasi dan membandingkan kinerja algoritma Support Vector Machine (SVM) dan K-Nearest Neighbors (KNN).



Gambar 1. Tahapan Penelitian Komparasi Penyakit Ginjal Dengan Machine Learning



1. Dataset Penyakit Ginjal

Penelitian ini menggunakan dataset penyakit ginjal yang terdiri dari 4.000 data, dengan distribusi yang seimbang pada setiap kelas. Dataset ini digunakan sebagai sumber data utama dalam pengembangan model deteksi penyakit ginjal berbasis machine learning. Sebelum digunakan, data diperiksa untuk memastikan kelengkapan atribut, konsistensi label, serta kesiapan data agar dapat diproses secara optimal pada tahap pelatihan model.

2. Pembagian Data Training dan Data Testing

Dataset yang telah disiapkan selanjutnya dibagi menjadi **data training dan data testing** dengan rasio **80:20**. Dari total 4.000 data, sebanyak **3.200 data** digunakan sebagai data training dan **800 data** digunakan sebagai data testing. Pembagian data dilakukan secara proporsional pada setiap kelas untuk menjaga keseimbangan distribusi data. Tahap ini bertujuan agar model memperoleh data pelatihan yang cukup sekaligus dapat diuji secara objektif terhadap data yang belum pernah digunakan sebelumnya.

3. Pelatihan Model Machine Learning

Pada tahap ini, **data training** digunakan untuk melatih dua algoritma machine learning, yaitu **Support Vector Machine (SVM)** dan **K-Nearest Neighbors (KNN)**, dengan tujuan membangun model klasifikasi penyakit ginjal yang mampu mengenali pola data secara akurat. Algoritma SVM bekerja dengan mencari hyperplane atau batas pemisah optimal yang dapat memisahkan data ke dalam kelas-kelas penyakit ginjal berdasarkan karakteristik atribut yang dimiliki. Dengan memaksimalkan margin antar kelas, SVM memiliki kemampuan generalisasi yang baik, sehingga efektif digunakan pada data dengan dimensi yang tinggi dan pola yang kompleks. Proses pelatihan SVM melibatkan penyesuaian parameter tertentu untuk menghasilkan model yang mampu membedakan setiap kelas penyakit secara optimal. Sementara itu, algoritma K-Nearest Neighbors (KNN) melakukan proses klasifikasi berdasarkan kedekatan jarak antara data uji dan data training terdekat. Model KNN tidak membangun model eksplisit seperti SVM, melainkan menyimpan seluruh data training dan menentukan kelas suatu data berdasarkan mayoritas kelas dari sejumlah tetangga terdekat. Kinerja KNN sangat dipengaruhi oleh pemilihan nilai parameter k serta metode pengukuran jarak yang digunakan. Dalam penelitian ini, kedua algoritma dilatih secara terpisah menggunakan data training yang sama untuk memastikan bahwa perbandingan kinerja yang dihasilkan bersifat adil, konsisten, dan objektif dalam mendeteksi penyakit ginjal.


4. Evaluasi Model

Model yang telah dilatih kemudian diuji menggunakan data testing untuk menilai kinerjanya dalam mendeteksi penyakit ginjal. Evaluasi dilakukan dengan membandingkan hasil prediksi model terhadap label sebenarnya, dengan fokus pada nilai akurasi sebagai indikator utama kinerja model. Model yang menghasilkan nilai akurasi lebih dari 80% ditetapkan sebagai model yang layak dan dipilih sebagai model terbaik. Apabila nilai akurasi belum memenuhi ambang batas tersebut, maka proses pelatihan dan evaluasi dapat diulang untuk meningkatkan performa model.

5. Model Deteksi Penyakit Ginjal

Model yang memenuhi kriteria akurasi selanjutnya ditetapkan sebagai **model deteksi penyakit ginjal**. Model ini diharapkan mampu digunakan sebagai alat bantu dalam mendukung deteksi dini penyakit ginjal secara otomatis dan objektif, serta dapat dikembangkan lebih lanjut untuk implementasi pada sistem pendukung keputusan di bidang kesehatan.





3. HASIL DAN PEMBAHASAN

3.1. Dataset

Dataset yang digunakan dalam penelitian ini terdiri dari 4.000 data pasien penyakit ginjal yang terbagi secara seimbang ke dalam empat kelas, dengan masing-masing kelas berjumlah 1.000 data. Setiap data merepresentasikan satu pasien dan memuat sejumlah atribut klinis serta hasil pemeriksaan laboratorium yang berkaitan dengan fungsi ginjal, seperti usia, tekanan darah, kadar kreatinin, kadar urea, kadar glukosa, hemoglobin, serta parameter medis lainnya. Distribusi data yang seimbang ini bertujuan untuk meminimalkan bias kelas dalam proses pelatihan dan pengujian model, sehingga memungkinkan evaluasi kinerja algoritma Support Vector Machine (SVM) dan K-Nearest Neighbors (KNN) dilakukan secara objektif dan adil. Data lengkap dari dataset penyakit ginjal terdapat pada Tabel 1.

Tabel 1. Dataset penyakit Fundus

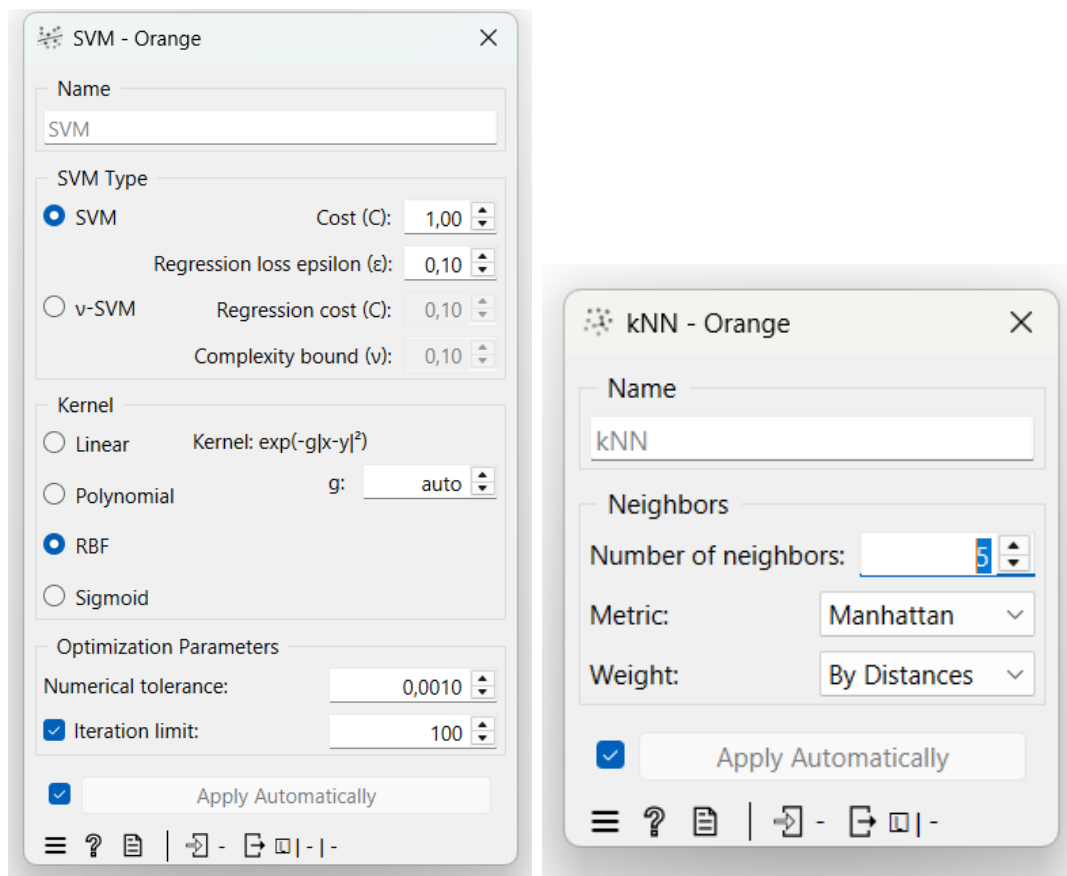
Nama Penyakit	Jumlah Data
Normal	1000
cyst	1000
Stone	1000
Tumoe	1000
Total	4000

3.2. Hasil Evaluasi Umum

Hasil evaluasi umum menunjukkan bahwa model klasifikasi penyakit ginjal yang dibangun menggunakan algoritma Support Vector Machine (SVM) dan K-Nearest Neighbors (KNN) mampu melakukan klasifikasi data dengan kinerja yang baik. Pengujian dilakukan menggunakan data testing yang dipisahkan dari data training berdasarkan rasio yang telah ditetapkan, sehingga evaluasi mencerminkan kemampuan generalisasi model terhadap data baru. Secara keseluruhan, kedua algoritma menunjukkan tingkat akurasi yang memenuhi kriteria kelayakan, yaitu di atas 80%, yang menandakan bahwa pendekatan machine learning efektif digunakan dalam mendeteksi penyakit ginjal berdasarkan dataset yang digunakan.

Perbedaan kinerja antara SVM dan KNN terlihat dari variasi nilai akurasi dan konsistensi hasil klasifikasi yang dihasilkan. SVM cenderung menunjukkan performa yang lebih stabil dalam memisahkan kelas penyakit ginjal, terutama pada data dengan pola yang kompleks, sementara KNN memberikan hasil yang cukup kompetitif dengan memanfaatkan kedekatan antar data. Hasil evaluasi ini menjadi dasar dalam proses seleksi model, di mana model dengan akurasi terbaik ditetapkan sebagai model deteksi penyakit ginjal. Temuan ini menunjukkan bahwa pemilihan algoritma yang tepat sangat berpengaruh terhadap keberhasilan sistem deteksi penyakit ginjal berbasis machine learning.





Gambar 2. Setting Parameter Model untuk SVM dan kNN

3.3. Hasil perbandingan metode

Hasil evaluasi kinerja model menunjukkan bahwa baik algoritma Support Vector Machine (SVM) maupun K-Nearest Neighbors (KNN) mampu memberikan performa yang sangat tinggi dalam mendeteksi penyakit ginjal berdasarkan dataset yang digunakan. Evaluasi dilakukan menggunakan data testing dengan mengukur metrik akurasi (CA), precision, recall, dan F1-score sebagai indikator utama kinerja model. Secara umum, nilai yang diperoleh menunjukkan bahwa kedua algoritma memiliki kemampuan klasifikasi yang sangat baik, dengan seluruh metrik evaluasi mendekati nilai maksimum, yang mengindikasikan tingkat kesalahan klasifikasi yang sangat rendah.

Pada algoritma **SVM**, hasil evaluasi menunjukkan nilai akurasi, precision, dan F1-score sebesar **0,996**, dengan nilai recall juga mencapai **0,996**. Hasil ini menunjukkan bahwa SVM mampu mengklasifikasikan data penyakit ginjal dengan tingkat ketepatan yang sangat tinggi serta memiliki keseimbangan yang baik antara kemampuan mendeteksi data positif dan meminimalkan kesalahan prediksi. Performa ini mencerminkan keunggulan SVM dalam membentuk batas pemisah optimal antar kelas, terutama pada dataset dengan pola yang kompleks dan jumlah data yang besar.

		Predicted				Σ
		Cyst	Normal	Stone	Tumor	
Actual	Cyst	990	0	10	0	1000
	Normal	0	999	1	0	1000
	Stone	5	0	995	0	1000
	Tumor	0	0	1	999	1000
Σ		995	999	1007	999	4000

Gambar 3. Hasil akurasi penyakit ginjal dengan SVM

Sementara itu, algoritma **KNN** menunjukkan performa yang sedikit lebih unggul dibandingkan SVM, dengan nilai akurasi, precision, dan F1-score sebesar **0,998**, serta nilai recall mencapai **0,998**. Hasil ini mengindikasikan bahwa KNN sangat efektif dalam mengenali pola data berdasarkan kedekatan antar sampel pada dataset penyakit ginjal yang digunakan. Tingginya nilai recall menunjukkan bahwa KNN memiliki kemampuan yang sangat baik dalam mendeteksi hampir seluruh data penyakit ginjal tanpa banyak kehilangan informasi. Berdasarkan hasil evaluasi tersebut, KNN dapat dinyatakan sebagai model dengan performa terbaik pada penelitian ini, meskipun kedua algoritma sama-sama memenuhi kriteria kelayakan sebagai model deteksi penyakit ginjal berbasis machine learning.

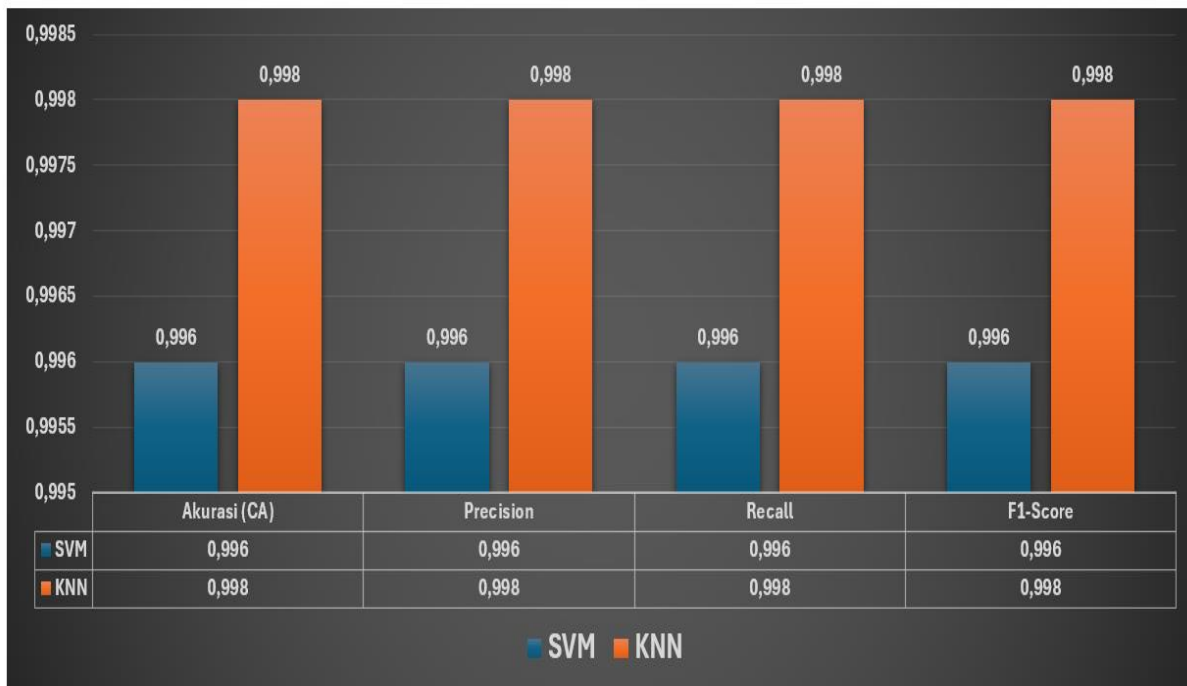
		Predicted				Σ
		Cyst	Normal	Stone	Tumor	
Actual	Cyst	1000	0	0	0	1000
	Normal	0	1000	0	0	1000
	Stone	6	1	993	0	1000
	Tumor	0	0	1	999	1000
Σ		1006	1001	994	999	4000

Gambar 4. Hasil akurasi penyakit ginjal dengan kNN


Tabel 2. Hasil Komparasi Metode untuk penyakit Ginjal

Model	Akurasi (CA)	Precision	Recall	F1-Score
SVM	0.996	0.996	0.996	0.996
KNN	0.998	0.998	0.998	0.998

Tabel ini menyajikan hasil evaluasi kinerja model deteksi penyakit ginjal menggunakan algoritma Support Vector Machine (SVM) dan K-Nearest Neighbors (KNN). Evaluasi dilakukan pada data testing dengan menggunakan metrik akurasi (CA), precision, recall, dan F1-score sebagai indikator utama performa model. Hasil yang ditampilkan merupakan nilai rata-rata dari seluruh kelas penyakit ginjal. Berdasarkan tabel tersebut, kedua algoritma menunjukkan kinerja yang sangat baik dengan nilai akurasi di atas 99%, di mana KNN menghasilkan performa tertinggi dibandingkan SVM. Perbedaan nilai waktu uji menunjukkan variasi efisiensi komputasi masing-masing algoritma, yang menjadi pertimbangan tambahan dalam pemilihan model terbaik.



Gambar 5. Hasil Komparasi Metode Machine Learning Untuk Deteksi Penyakit Ginjal



4. KESIMPULAN

Penelitian ini dilakukan untuk mengkaji efektivitas metode machine learning dalam mendeteksi penyakit ginjal berdasarkan data medis pasien. Dengan menggunakan dataset yang terdiri dari **4.000 data** yang terbagi secara seimbang ke dalam **empat kelas**, penelitian ini membandingkan kinerja dua algoritma, yaitu **Support Vector Machine (SVM)** dan **K-Nearest Neighbors (KNN)**. Hasil penelitian menunjukkan bahwa kedua algoritma mampu melakukan klasifikasi penyakit ginjal dengan tingkat akurasi yang sangat tinggi, yang mengindikasikan bahwa pendekatan machine learning dapat menjadi solusi yang andal dalam membantu proses deteksi penyakit ginjal secara otomatis dan objektif.

Berdasarkan hasil evaluasi kinerja model, algoritma **SVM** menghasilkan nilai akurasi sebesar **99,6%**, sedangkan algoritma **KNN** menunjukkan performa yang sedikit lebih unggul dengan nilai akurasi sebesar **99,8%**, disertai nilai precision, recall, dan F1-score yang konsisten. Perbedaan performa ini menunjukkan bahwa KNN lebih efektif dalam memanfaatkan kedekatan antar data pada dataset yang digunakan, sementara SVM tetap menunjukkan kemampuan generalisasi yang sangat baik dalam memisahkan kelas penyakit ginjal. Dengan mempertimbangkan ambang batas akurasi yang telah ditetapkan, kedua model dinyatakan layak digunakan sebagai model deteksi penyakit ginjal, dengan KNN sebagai model dengan performa terbaik.

Meskipun hasil penelitian menunjukkan tingkat akurasi yang sangat tinggi, penelitian ini masih memiliki beberapa keterbatasan, seperti penggunaan dataset dengan karakteristik tertentu dan keterbatasan variasi data yang merepresentasikan kondisi klinis nyata secara lebih luas. Oleh karena itu, untuk penelitian selanjutnya disarankan untuk menggunakan dataset yang lebih beragam, menguji model pada data real-world, serta mengembangkan pendekatan hybrid atau membandingkan dengan metode deep learning guna meningkatkan robustnes dan kemampuan generalisasi model dalam mendeteksi penyakit ginjal di berbagai kondisi klinis.


5. REFERENCES

- [1] M. K. Samatha, M. M. R. Reddy, M. P. F. Khan, M. R. A. Chowdary, and P. V. R. . P. Rao, "Chronic Kidney Disease Prediction Using Machine Learning Algorithms," *Int. J. Prev. Med. Heal.*, vol. 1, no. 3, pp. 1–4, 2021, doi: 10.35940/ijpmh.c1010.071321.
- [2] S. raj, K. Attri, S. Chawla, and S. Rastogi, "Comparative Analysis of Kidney Failure Prediction at an Early Stage Using Machine Learning Algorithms," *Ijeast*, vol. 7, no. 9, pp. 76–83, 2023, doi: 10.33564/ijeast.2023.v07i09.013.
- [3] A. A. Siddiqi, A. Khawaja, and A. Hashmi, "Classification of Abdominal CT Images Bearing Liver Tumor Using Structural Similarity Index and Support Vector Machine," *Mehran Univ. Res. J. Eng. Technol.*, vol. 39, no. 4, pp. 751–758, 2020, doi: 10.22581/muet1982.2004.07.
- [4] H. Feng, Q. Tang, Z. Yu, T. Hua, M. Yin, and W. An, "A Machine Learning Applied Diagnosis Method for Subcutaneous Cyst by Ultrasonography," *Oxid. Med. Cell. Longev.*, vol. 2022, no. 1, 2022, doi: 10.1155/2022/1526540.
- [5] A. Hassanein, "Kid-MI: ML for Kidney Malignant Tissues Identification," *Msa Eng. J.*, vol. 2, no. 2, pp. 1120–1134, 2023, doi: 10.21608/msaeng.2023.291932.
- [6] H. Ç. Reis, V. Turk, and S. KAYA, "Detection of COVID-19 Infection From CT Images Using the Medical Photogrammetry Technique," *Mersin Photogramm. J.*, vol. 5, no. 2, pp. 42–54, 2023, doi: 10.53093/mephoj.1301980.
- [7] M. M. E. Sherbiny, E. AbdElhalim, H. E. Mostafa, and M. El-Seddek, "Classification of Chronic Kidney Disease Based on Machine Learning Techniques," *Indones. J. Electr. Eng. Comput. Sci.*, vol. 32, no. 2, p. 945, 2023, doi: 10.11591/ijeecs.v32.i2.pp945-955.
- [8] J. Chen *et al.*, "Ultrasound-Based Radiomics for the Classification of Henoch-Schönlein Purpura Nephritis in Children," *Ultrason. Imaging*, vol. 46, no. 2, pp. 110–120, 2023, doi: 10.1177/01617346231220000.

Sumanto: *Penulis Korespondensi



Copyright © 2025, Deny Kurniawan, Dedi Triyanto, Lita Sari Marita, Ade Christian, Sumanto.



- [9] R. Singla *et al.*, "Automatic Measurement of Kidney Dimensions in Two-Dimensional Ultrasonography Is Comparable to Expert Sonographers," *J. Med. Imaging*, vol. 10, no. 03, 2023, doi: 10.1117/1.jmi.10.3.034003.
- [10] Y. Yang, H. Chen, Y. Li, and J. Zhou, "Case Report: The Ultrasound Features of Acquired Cystic Disease-Associated Renal Cell Carcinoma: A Case Series," *Front. Oncol.*, vol. 13, 2023, doi: 10.3389/fonc.2023.1187495.
- [11] Z. Hu *et al.*, "Improved Predictions of Total Kidney Volume Growth Rate in ADPKD Using Two-Parameter Least Squares Fitting," *Sci. Rep.*, vol. 14, no. 1, 2024, doi: 10.1038/s41598-024-62776-8.
- [12] A. B. N. P. Sirisha, N. Dhanalakshmi, and S. S. Priyanka, "Optimized SVM With BWA for CKD Prediction," 2024, doi: 10.21203/rs.3.rs-4361402/v1.
- [13] J. Deepika *et al.*, "Efficient Classification of Kidney Disease Detection Using Heterogeneous Modified Artificial Neural Network and Fruit Fly Optimization Algorithm," *J. Adv. Res. Appl. Sci. Eng. Technol.*, vol. 31, no. 3, pp. 1–12, 2023, doi: 10.37934/araset.31.3.112.
- [14] W. W. Fung *et al.*, "Clinical Characteristics and Kidney Outcomes in Chinese Patients With Autosomal Dominant Polycystic Kidney Disease," *Kidney360*, vol. 5, no. 5, pp. 715–723, 2024, doi: 10.34067/kid.0000000000000433.
- [15] V. Singh, V. K. Asari, and R. Rajkumar, "A Deep Neural Network for Early Detection and Prediction of Chronic Kidney Disease," *Diagnostics*, 2022, doi: 10.3390/diagnostics12010116.
- [16] Z. Liu, S. Li, J. Hao, J. Hu, and M. Pan, "An Efficient and Fast Model Reduced Kernel KNN for Human Activity Recognition," *J. Adv. Transp.*, vol. 2021, pp. 1–9, 2021, doi: 10.1155/2021/2026895.
- [17] G. Huang, L. Qiao, S. Khanna, P. A. Pavlovich, and S. Tiwari, "Research on Fan Vibration Fault Diagnosis Based on Image Recognition," *J. Vibroengineering*, vol. 23, no. 6, pp. 1366–1382, 2021, doi: 10.21595/jve.2021.21935.
- [18] S. AlZu'bi *et al.*, "Diabetes Monitoring System in Smart Health Cities Based on Big Data Intelligence," *Futur. Internet*, vol. 15, no. 2, 2023, doi: 10.3390/fi15020085.
- [19] R. W. Walmer *et al.*, "The Performance of Flash Replenishment Contrast-Enhanced Ultrasound for the Qualitative Assessment of Kidney Lesions in Patients With Chronic Kidney Disease," *J. Clin. Med.*, vol. 12, no. 20, p. 6494, 2023, doi: 10.3390/jcm12206494.
- [20] K. T. Bae and J. J. Grantham, "Imaging for the Prognosis of Autosomal Dominant Polycystic Kidney Disease," *Nat. Rev. Nephrol.*, vol. 6, no. 2, pp. 96–106, 2010, doi: 10.1038/nrneph.2009.214.

