

Implementasi model *support vector machine* sebagai sistem prediksi penyakit ginjal kronik berbasis data klinis

^{1*}Rama Dian Syah, ²Diandra Hasna Widiyanto, ³Bhakti Gunawan, ⁴Hadyanto Caputra, ⁵Widya Silfianti, ⁶Rena Fuji Erin Setyawati

^{1,5}Fakultas Ilmu Komputer dan Teknologi Informasi, ^{2,3,4,6}Fakultas Kedokteran
Universitas Gunadarma, Jalan Margonda Raya No. 100, Depok, Jawa Barat

¹rama_ds@staff.gunadarma.ac.id, ²diandrahasnaw@gmail.com, ³bhakti@staff.gunadarma.ac.id,
⁴drhadysppd@gmail.com, ⁵wsilfi@staff.gunadarma.ac.id, ⁶renaerin@staff.gunadarma.ac.id

Abstract

Chronic Kidney Disease (CKD) is one of the global health problems with increasing prevalence and mortality rates, requiring accurate early detection methods to support timely treatment and prevention. Various previous studies have applied machine learning techniques for CKD prediction; however, most studies are still limited to basic model implementation without systematic parameter optimization or real-time web-based prediction system deployment. This study aims to develop a CKD prediction model using the Support Vector Machine (SVM) algorithm optimized through GridSearchCV to improve classification performance. The research was conducted based on the CRISP-DM framework using the CKD dataset from the UCI Machine Learning Repository. The preprocessing stage included categorical data transformation, missing value handling using median imputation, and feature standardization using StandardScaler. Parameter optimization was performed by testing several SVM parameter combinations using a 5-fold cross-validation approach. The results showed that the optimized SVM model achieved an accuracy of 98.75%, with high precision, recall, and F1-score values in CKD and non-CKD classification. These results indicate better performance compared to several previous studies using similar datasets with accuracy below 98%. Furthermore, the model was implemented in a web-based application using Gradio and Hugging Face Spaces to support real-time prediction. Initial validation by an internal medicine specialist indicated that the system predictions were consistent with medical interpretation, suggesting that the proposed model has potential as a decision-support tool for early CKD detection.

Keywords: chronic kidney disease, GridSearchCV, machine learning, Support Vector Machine, web-based prediction system

Abstrak

Penyakit Ginjal Kronis (PGK) merupakan salah satu penyakit dengan tingkat prevalensi dan mortalitas yang terus meningkat, sehingga diperlukan metode deteksi dini yang akurat untuk mendukung penanganan lebih cepat. Berbagai penelitian telah menerapkan *machine learning* untuk prediksi PGK, namun sebagian besar masih terbatas pada implementasi model tanpa optimasi parameter yang sistematis maupun implementasi sistem prediksi berbasis web secara *real-time*. Penelitian ini bertujuan mengembangkan model prediksi PGK menggunakan algoritma *Support Vector Machine* (SVM) yang dioptimasi melalui *GridSearchCV* untuk meningkatkan performa klasifikasi. Penelitian dilakukan berdasarkan kerangka kerja CRISP-DM menggunakan *dataset* PGK dari *UCI Machine Learning Repository*. Tahap pra-proses meliputi transformasi data kategorikal, penanganan *missing value* menggunakan median *imputation*, serta standarisasi fitur menggunakan *StandardScaler*. Proses optimasi dilakukan dengan pengujian beberapa kombinasi parameter SVM menggunakan pendekatan *5-fold cross-validation*. Hasil penelitian menunjukkan bahwa model SVM yang dioptimasi mampu mencapai akurasi sebesar 98.75% dengan nilai

precision, *recall*, dan *F1-score* yang tinggi pada pada klasifikasi PGK dan non-PGK. Hasil tersebut menunjukkan performa yang lebih baik dibandingkan beberapa penelitian sebelumnya pada dataset serupa dengan akurasi di bawah 98%. Selain itu, model diimplementasikan dalam aplikasi berbasis web menggunakan *Gradio* dan *Hugging Face Spaces* untuk mendukung prediksi secara *real-time*. Hasil validasi awal oleh dokter spesialis penyakit dalam menunjukkan bahwa keluaran sistem sesuai dengan interpretasi medis, sehingga model berpotensi digunakan sebagai alat bantu deteksi dini PGK.

Kata Kunci: GridSearchCV, *machine learning*, penyakit ginjal kronis, sistem prediksi berbasis web, *Support Vector Machine*

1. Pendahuluan

Penyakit Ginjal Kronik (PGK) atau *Chronic Kidney Disease* (CKD) menjadi salah satu isu kesehatan prioritas baik di tingkat global maupun nasional dengan adanya peningkatan jumlah kasus yang terjadi secara konsisten dari waktu ke waktu. Kondisi ini tidak terlepas dari tingginya angka kejadian penyakit penyerta, khususnya obesitas dan diabetes melitus, yang berperan sebagai faktor risiko utama terjadinya PGK. Jumlah penderita PGK secara global diperkirakan mencapai 843 juta orang pada tahun 2017 [1]. Selain itu, PGK termasuk dalam kelompok penyakit dengan kontribusi besar terhadap angka kematian dunia, dengan insidensi yang melampaui 11 juta kasus dan prevalensi lebih dari 358 juta kasus pada tahun 2021 berdasarkan laporan *Global Burden of Disease* (GBD). Penyakit ini juga dilaporkan menjadi penyebab kematian dengan angka lebih dari 1,5 juta setiap tahunnya [2].

Situasi serupa juga terjadi pada tingkat nasional. Prevalensi PGK, berdasarkan hasil Riset Kesehatan Dasar (Riskesdas) tahun 2018, tercatat sebesar 0,38%. Hal ini menunjukkan bahwa setara dengan 3,8 kasus per 1000 penduduk. Data tersebut menunjukkan bahwa sebagian besar penderita berada pada kondisi yang memerlukan penanganan lanjutan, termasuk terapi dialisis sebagai bentuk pengobatan utama [3].

PGK dikenal sebagai kondisi yang berkembang secara bertahap dan bersifat permanen, ditandai dengan penurunan fungsi ginjal yang terus berlangsung hingga mencapai tahap akhir atau *End Stage Renal Disease* (ESRD) [4]. Perkembangan penyakit ini tidak hanya menurunkan kualitas hidup penderita, tetapi juga memberikan tekanan yang cukup besar terhadap sistem pembiayaan layanan kesehatan. Salah satu kendala utama dalam pengelolaan PGK adalah keterlambatan diagnosis akibat minimnya gejala klinis pada fase awal sehingga PGK baru teridentifikasi ketika kondisi sudah memasuki tahap lanjut [5].

Dalam praktik medis, proses diagnosis umumnya dilakukan melalui pemeriksaan laboratorium, seperti perhitungan *Glomerular Filtration Rate* (GFR), yang memerlukan waktu, biaya, serta fasilitas tertentu yang tidak selalu tersedia di semua layanan kesehatan [6]. Kondisi ini menunjukkan perlunya alternatif pendekatan untuk mendukung upaya deteksi dini lebih cepat secara akurat dan efisien.

Inovasi *Artificial Intelligence* (AI), khususnya pada bidang *Machine Learning* (ML), telah mendorong perkembangan sistem prediksi penyakit yang lebih adaptif dan akurat dalam mendukung pengambilan keputusan medis. Berbagai algoritma ML telah diterapkan pada kasus prediksi PGK, seperti *Logistic Regression*, *Decision Tree*, *Random Forest*, *Artificial Neural Network*, dan *Support Vector Machine* (SVM) [7], [8], [9]. Sejumlah penelitian menunjukkan bahwa metode *ensemble* seperti *Random Forest* mampu memberikan stabilitas performa pada data medis yang kompleks, sedangkan *Logistic Regression* unggul dalam interpretabilitas model. Namun, beberapa metode tersebut cenderung mengalami penurunan performa ketika menghadapi data berdimensi tinggi, distribusi data yang tidak seimbang, maupun hubungan non-linear antar atribut. Dalam kondisi tersebut, SVM dikenal memiliki

kemampuan generalisasi yang lebih baik karena mampu membentuk *hyperplane* optimal dan memanfaatkan fungsi kernel untuk menangani pola non-linear secara efektif [10], [11]. Selain itu, SVM relatif lebih *robust* terhadap *overfitting* pada *dataset* dengan jumlah data terbatas yang umum ditemukan pada data medis [12].

Meskipun demikian, kajian terhadap penelitian sebelumnya menunjukkan bahwa sebagian besar penelitian terkait prediksi PGK menggunakan SVM masih berfokus pada implementasi model dasar tanpa analisis komparatif yang mendalam terhadap pengaruh konfigurasi parameter maupun strategi optimasi yang digunakan. Banyak penelitian menerapkan parameter *default* tanpa melakukan proses *tuning* secara sistematis terhadap parameter penting seperti kernel, nilai C, dan gamma, padahal parameter tersebut berpengaruh signifikan terhadap kemampuan klasifikasi model. Di sisi lain, penelitian terdahulu umumnya hanya berorientasi pada pencapaian nilai akurasi, sementara aspek interpretasi performa model, stabilitas klasifikasi, serta kesiapan model untuk digunakan dalam skenario deteksi dini masih belum banyak dibahas. Selain itu, integrasi model prediksi ke dalam sistem yang dapat digunakan secara langsung oleh pengguna akhir masih terbatas, sehingga kontribusi penelitian sering kali berhenti pada tahap eksperimental.

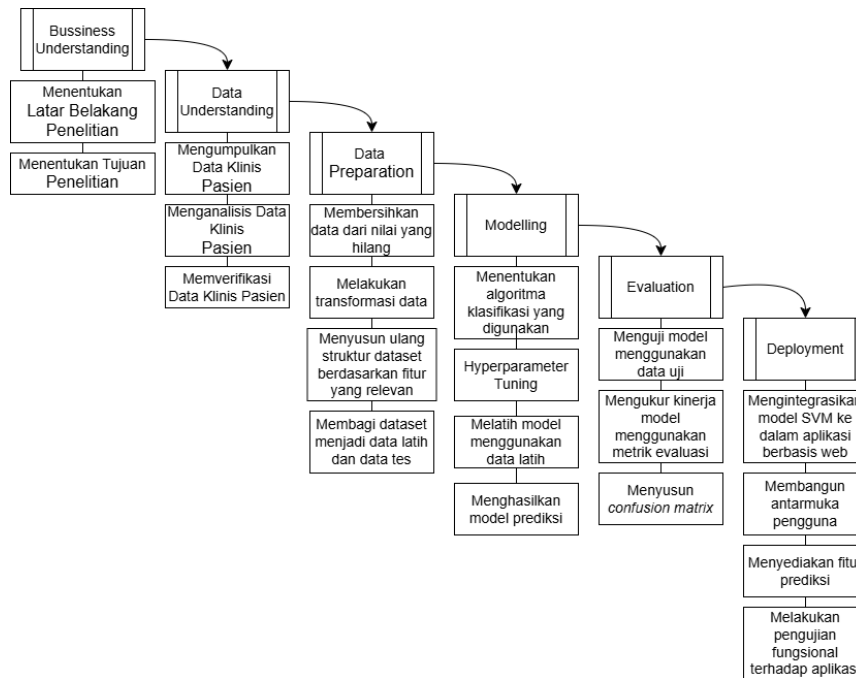
Berdasarkan kondisi tersebut, *research gap* dalam penelitian ini terletak pada belum optimalnya penerapan dan evaluasi SVM untuk prediksi PGK melalui proses optimasi parameter yang terstruktur serta minimnya pengembangan sistem prediksi yang tidak hanya berorientasi pada implementasi teknis, tetapi juga pada peningkatan kualitas performa klasifikasi dan potensi pemanfaatannya dalam deteksi dini. Oleh karena itu, penelitian ini mengusulkan pendekatan prediksi PGK menggunakan algoritma SVM yang dioptimasi melalui pencarian parameter terbaik untuk memperoleh model dengan performa klasifikasi yang lebih optimal dan stabil. Pendekatan ini tidak hanya menitikberatkan pada implementasi *GridSearchCV* sebagai proses *tuning* parameter, tetapi juga pada analisis pengaruh optimasi parameter terhadap peningkatan performa model dalam memprediksi PGK.

Secara lebih spesifik, tujuan penelitian ini adalah menganalisis performa algoritma SVM dalam prediksi PGK, mengoptimasi parameter SVM untuk meningkatkan akurasi dan kemampuan generalisasi model, serta mengembangkan prototipe sistem berbasis web yang mampu mendukung proses deteksi dini PGK. Kontribusi utama penelitian ini terletak pada penguatan pendekatan optimasi SVM melalui evaluasi parameter yang komprehensif, analisis performa model pada kasus prediksi PGK, serta pengembangan sistem prediksi yang memiliki nilai implementasi dalam mendukung pengambilan keputusan di bidang kesehatan. Dengan demikian, penelitian ini diharapkan dapat memberikan kontribusi baik secara akademis dalam pengembangan model prediksi berbasis ML dalam mendukung upaya deteksi dini PGK.

2. Metode Penelitian

Penelitian ini menggunakan perangkat lunak Google Colab untuk membangun model ML serta rancangan prototipe *website* diimplementasikan menggunakan platform *Hugging Face*. *Dataset* yang digunakan merupakan data pasien *Chronic Kidney Disease* yang diperoleh dari UCI *dataset* [13]. Metode penelitian pada penelitian ini menggunakan CRISP-DM. Metode penelitian CRISP-DM dipilih karena mampu mengakomodasi kebutuhan analisis data medis yang kompleks, mulai dari pemahaman permasalahan klinis hingga implementasi model ke dalam sistem berbasis aplikasi [14]. CRISP-DM dapat memastikan setiap tahapan penelitian, khususnya pada proses *data preparation* dan pemodelan, dilakukan secara sistematis sehingga dapat meningkatkan kualitas model yang dihasilkan [15]. Gambar 1 memperlihatkan alur penerapan metodologi CRISP-DM dalam penelitian ini. Penelitian ini

berfokus pada prediksi resiko penyakit PGK pada seorang pasien berdasarkan data klinis pasien. Algoritma SVM digunakan sebagai pendekatan utama dalam membangun model *machine learning* pada penelitian ini.



Gambar 1. Metode penelitian CRISP-DM

2.1 Business Understanding

Tahap *Business Understanding* dalam penelitian ini berfokus pada identifikasi permasalahan dan penentuan tujuan penelitian terkait prediksi PGK. Permasalahan utama yang diangkat adalah tingginya angka kejadian PGK serta keterlambatan diagnosis akibat keterbatasan metode konvensional yang umumnya bergantung pada pemeriksaan laboratorium [16]. Kondisi tersebut menunjukkan adanya kebutuhan akan suatu pendekatan alternatif yang mampu mendukung deteksi dini secara lebih cepat dan efisien. Berdasarkan permasalahan yang telah diuraikan, penelitian ini difokuskan pada pengembangan model prediksi PGK dengan memanfaatkan pendekatan ML, khususnya algoritma SVM, untuk mengestimasi risiko penyakit berdasarkan data klinis pasien. Selain itu, model yang dihasilkan tidak hanya dievaluasi secara konseptual, tetapi juga diimplementasikan ke dalam sebuah prototipe aplikasi berbasis web guna mempermudah pengguna dalam melakukan prediksi secara lebih praktis dan mudah diakses. Dengan adanya perancangan tersebut, penelitian ini diharapkan mampu memberikan arah yang jelas dalam proses pengembangan sistem sekaligus memastikan bahwa solusi yang dibangun selaras dengan kebutuhan permasalahan yang dihadapi.

2.2 Data Understanding

Analisis terhadap karakteristik dan kualitas data klinis pasien dilakukan pada tahap *Data Understanding* sebagai dasar dalam membangun model yang akan dikembangkan. *Dataset* yang digunakan berupa data *Chronic Kidney Disease* dengan 400 data klinis pasien yang bersumber dari *UCI Machine Learning Repository* [13]. Tahap ini mencakup eksplorasi data untuk memahami struktur *dataset*, mengidentifikasi tipe atribut, serta menganalisis distribusi nilai pada setiap variabel. Selain itu, dilakukan analisis awal untuk mendeteksi

adanya nilai yang hilang (*missing values*), inkonsistensi data, maupun potensi *outlier* yang dapat memengaruhi kinerja model. Proses verifikasi data juga dilakukan untuk memastikan kesesuaian data dengan kebutuhan penelitian serta validitas informasi yang terkandung di dalamnya. Tabel 1 menyajikan atribut klinis yang terdapat dalam *dataset Chronic Kidney Disease* yang bersumber dari *UCI Machine Learning Repository*.

Tabel 1. Atribut klinis pada *dataset*

No	Variabel	Deskripsi	Alat Ukur	Satuan Ukur	Skala Ukur	Missing Value
1	Prediksi PGK	Diagnosis PGK	Diagnosis oleh dokter	Non-PGK, PGK	Kategorik	Tidak
2	Usia (<i>age</i>)	Usia pasien dalam tahun	Data rekam medis pasien	Tahun	Numerik	Ya
3	Tekanan Darah (<i>blood pressure</i>)	Tekanan darah pasien (diastolik) dalam mmHg	Sfigmomanometer	mmHg	Numerik	Ya
4	Berat Jenis Urine (<i>specific Gravity</i>)	Rasio densitas urine dengan densitas air	<i>Semi automated urine Analyzer</i>	0,0-2,0	Numerik	Ya
5	Albumin	Kadar albumin di urin yang dihitung secara semikuantitatif	Dipstick	g/dL	Numerik	Ya
6	Gula dalam Urine (<i>sugar</i>)	Kadar gula di urine	<i>Dipstick</i>	mg/dL	Numerik	Ya
7	Eritrosit dalam Urine (<i>red blood cells</i>)	Persentase sel darah merah di urine	Mikroskop binokuler	Normal: 0-2 sel/LPK Abnormal: >3 sel/LPK	Numerik	Ya
8	Leukosit dalam Urine (<i>pus cell/ pus cell clumps</i>)	Sel darah putih di urine	Mikroskop binokuler	Yes, No	Kategorik	Ya
9	Bakteri dalam Urine (<i>bacteria</i>)	Tanda adanya bakteri di urine	Mikroskop binokuler, <i>low speed centrifuge</i>	Yes, No	Kategorik	Ya
10	Gula Darah Sewaktu (<i>blood glucose random</i>)	Tes gula darah acak	<i>Chemistry Analyzer</i>	mg/dL	Numerik	Ya
11	Urea dalam darah (<i>blood urea</i>)	Persentase urea nitrogen di plasma darah	<i>Chemistry Analyzer</i>	mg/dL	Numerik	Ya
12	Serum Kreatinin (<i>serum creatinine</i>)	Kadar kreatinin di otot pasien	<i>Chemistry Analyzer</i>	mg/dL	Numerik	Ya
13	Natrium (<i>sodium</i>)	Kadar sodium di darah	<i>Chemistry Analyzer</i>	mEq/L	Numerik	Ya
14	Kalium (<i>potassium</i>)	Kadar potassium di darah	<i>Chemistry Analyzer</i>	mEq/L	Numerik	Ya

No	Variabel	Deskripsi	Alat Ukur	Satuan Ukur	Skala Ukur	Missing Value
15	Hemoglobin	Protein yang bertanggung jawab membawa oksigen di dalam darah	<i>Hematology Analyzer</i>	g/dL	Numerik	Ya
16	Hematokrit (<i>packed cell volume</i>)	Volume sel darah di sampel darah	<i>Hematology Analyzer</i>	%	Numerik	Ya
17	Jumlah Sel darah Putih (<i>white blood cell count</i>)	Kadar hitung sel darah putih	<i>Hematology Analyzer</i>	10 ³ /μL	Numerik	Ya
18	Jumlah Sel darah Merah (<i>red blood cell count</i>)	Kadar hitung sel darah merah	<i>Hematology Analyzer</i>	10 ⁶ /μL	Numerik	Ya
19	Hipertensi (<i>hypertension</i>)	Tekanan darah yang tinggi secara terus menerus	Sfigmomanometer	Yes, No	Kategorik	Ya
20	Diabetes Mellitus	Gangguan produksi atau respon insulin yang mengganggu metabolisme glukosa	Riwayat diagnosis sebelumnya	Yes, No	Kategorik	Ya
22	<i>Coronary Artery Disease</i>	Keadaan terganggunya suplai nutrisi, oksigen, dan darah yang cukup ke jantung	Riwayat diagnosis sebelumnya	Yes, No	Kategorik	Ya
22	Nafsu Makan (<i>appetite</i>)	Keinginan untuk makan makanan	Data rekam medis pasien	Good, Poor	Kategorik	Ya
23	Edema Tungkai (<i>pedal edema</i>)	Pembengkakan kaki akibat cedera atau inflamasi	Data rekam medis pasien	Yes, No	Kategorik	Ya
24	Anemia	Insufisiensi transpor sel darah merah dalam membawa oksigen ke jaringan tubuh	Riwayat diagnosis sebelumnya	Yes, No	Kategorik	Ya

Tabel 1 menyajikan sejumlah variabel klinis yang digunakan dalam penelitian ini untuk merepresentasikan kondisi kesehatan pasien terkait PGK. Dalam *dataset* tersebut, variabel target yang digunakan adalah *class*, yang berfungsi sebagai penanda hasil diagnosis pasien ke dalam dua kategori, yaitu PGK dan non-PGK, berdasarkan evaluasi medis. Selain itu, *dataset* mencakup berbagai atribut prediktor yang berasal dari data rekam medis, hasil pemeriksaan laboratorium, serta hasil observasi klinis. Atribut numerik meliputi usia (*age*), tekanan darah (*blood pressure*), *specific gravity*, kadar albumin dan gula dalam urine, kadar glukosa darah acak, urea, kreatinin serum, elektrolit seperti natrium dan kalium, serta parameter hematologi seperti hemoglobin, *packed cell volume*, dan jumlah sel darah putih maupun merah. Sementara itu, atribut kategorikal mencakup kondisi klinis seperti keberadaan sel darah merah dan sel nanah dalam urine, adanya bakteri, hipertensi, diabetes melitus, penyakit arteri koroner, nafsu makan, edema, serta anemia. Setiap variabel diukur menggunakan alat medis tertentu dengan satuan ukur yang sesuai standar klinis, seperti mmHg untuk tekanan darah dan mg/dL untuk parameter biokimia. Selain itu, sebagian besar atribut dalam *dataset*

memiliki nilai yang hilang (*missing values*), sehingga diperlukan penanganan khusus pada tahap *data preparation*. Dengan keberagaman atribut tersebut, *dataset* ini mampu merepresentasikan kondisi klinis pasien secara komprehensif dan mendukung proses analisis serta pemodelan dalam prediksi PGK.

2.3 Data Preparation

Peningkatan kualitas data dilakukan pada tahap *data preparation* sebagai langkah awal sebelum proses pemodelan. Proses diawali dengan pembersihan data dari nilai yang hilang (*missing values*) [17]. *Dataset Chronic Kidney Disease* dari UCI memiliki beberapa atribut dengan nilai yang tidak lengkap, sehingga dilakukan penanganan dengan metode imputasi menggunakan nilai median pada setiap fitur numerik. Pemilihan median bertujuan untuk mengurangi pengaruh *outlier* terhadap distribusi data [18].

Selanjutnya dilakukan transformasi data, khususnya pada variabel kategorikal. Atribut seperti *red blood cells*, *pus cell*, *bacteria*, *hypertension*, dan atribut kategorikal lainnya dikonversi menjadi bentuk numerik menggunakan teknik *label encoding*. Proses ini diperlukan agar data dapat diproses oleh algoritma SVM yang hanya menerima *input* numerik.

Atribut kategorikal dalam *dataset Chronic Kidney Disease* dikonversi ke dalam bentuk numerik melalui proses *encoding* agar dapat digunakan dalam pemodelan. Variabel *red blood cells* (*rbc*) dan *pus cell* (*pc*) direpresentasikan dengan nilai 0 untuk kondisi normal dan 1 untuk kondisi abnormal. Selanjutnya, atribut seperti *pus cell clumps* (*pcc*) dan *bacteria* (*ba*) dikodekan dengan nilai 0 untuk kondisi tidak ada (*not present*) dan 1 untuk kondisi ada (*present*). Variabel lain, termasuk *hypertension* (*htn*), *diabetes mellitus* (*dm*), *coronary artery disease* (*cad*), *pedal edema*, dan anemia, menggunakan representasi biner dengan nilai 0 untuk “tidak” dan 1 untuk “ya”. Sementara itu, atribut *appetite* (*appet*) dikonversi menjadi 0 untuk kondisi *poor* dan 1 untuk *good*. Adapun variabel target (*class*) direpresentasikan dengan nilai 0 untuk non-PGK dan 1 untuk PGK. Proses transformasi ini dilakukan untuk memastikan seluruh data berada dalam format numerik sehingga dapat diproses oleh algoritma SVM secara optimal.

Tahap berikutnya adalah penyusunan ulang struktur *dataset* berdasarkan fitur yang relevan. Variabel target (*class*) dipisahkan dari variabel independen, sehingga diperoleh matriks fitur (*X*) dan label (*Y*). Struktur ini disesuaikan dengan kebutuhan proses pelatihan model ML yang terlihat pada Tabel 2.

Tabel 2. Contoh data sebelum dan setelah pembersihan serta transformasi

No	age	bp	sg	al	su	rbc	pc	pcc	ba	htn	dm	cad	appet	class
Data awal														
1	48.0	80.0	1.020	1.0	0.0	NaN	normal	<i>notpresent</i>	<i>notpresent</i>	<i>yes</i>	<i>yes</i>	<i>no</i>	<i>good</i>	PGK
2	7.0	50.0	1.020	4.0	0.0	NaN	normal	<i>notpresent</i>	<i>notpresent</i>	<i>no</i>	<i>no</i>	<i>no</i>	<i>good</i>	PGK
3	62.0	80.0	1.010	2.0	3.0	normal	normal	<i>notpresent</i>	<i>notpresent</i>	<i>no</i>	<i>yes</i>	<i>no</i>	<i>poor</i>	PGK
4	48.0	70.0	1.005	4.0	0.0	normal	abnormal	<i>present</i>	<i>notpresent</i>	<i>yes</i>	<i>no</i>	<i>no</i>	<i>poor</i>	PGK
5	51.0	80.0	1.010	2.0	0.0	normal	normal	<i>notpresent</i>	<i>notpresent</i>	<i>no</i>	<i>no</i>	<i>no</i>	<i>good</i>	PGK
Data setelah pembersihan dan transformasi														
1	48.0	80.0	1.020	1.0	0.0	0.0	0.0	0.0	0.0	1.0	1.0	0.0	1.0	1
2	7.0	50.0	1.020	4.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	1
3	62.0	80.0	1.010	2.0	3.0	0.0	0.0	0.0	0.0	0.0	1.0	0.0	0.0	1
4	48.0	70.0	1.005	4.0	0.0	0.0	1.0	1.0	0.0	1.0	0.0	0.0	0.0	1
5	51.0	80.0	1.010	2.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	0.0	1.0	1

Setelah itu, *dataset* dibagi menjadi data latih (*training data*) dan data uji (*testing data*) dengan rasio 80:20. Hasil pembagian data didapatkan model latih menggunakan 320 data pasien, model uji menggunakan 80 data pasien yang belum pernah dilihat sebelumnya. Data latih digunakan dalam proses pembentukan model, sementara data uji dimanfaatkan untuk mengevaluasi kinerja model terhadap data yang belum pernah digunakan sebelumnya [19], [20].

2.4 Modelling

Pada tahap pemodelan, penelitian ini menerapkan metode SVM sebagai model klasifikasi utama untuk mengidentifikasi risiko PGK. Algoritma SVM dipilih karena memiliki kemampuan generalisasi yang baik dalam menangani data berdimensi tinggi serta mampu membentuk *hyperplane* optimal untuk memisahkan kelas secara lebih akurat [21]. Selain itu, SVM dinilai efektif dalam menangani hubungan non-linear antar fitur melalui penggunaan fungsi kernel, sehingga banyak digunakan pada kasus klasifikasi data klinis.

Sebelum proses pelatihan model dilakukan, *dataset* terlebih dahulu dibagi menjadi data latih dan data uji menggunakan skema *train-test split* dengan proporsi 80% data latih dan 20% data uji serta *random_state* sebesar 42 untuk menjaga konsistensi hasil eksperimen. Selanjutnya, data latih dan data uji ditransformasikan menggunakan metode *StandardScaler* agar seluruh fitur memiliki rentang skala yang seragam. Proses normalisasi penting dalam penerapan SVM karena algoritma SVM sensitif terhadap perbedaan skala antar fitur, sehingga standardisasi dapat membantu meningkatkan stabilitas dan performa model.

Untuk memperoleh konfigurasi model yang optimal, penelitian ini menerapkan proses *hyperparameter tuning* menggunakan metode *GridSearchCV*. Proses *tuning* dilakukan dengan pendekatan *cross-validation* sebanyak *5-fold* dengan data latih dibagi menjadi lima *subset* secara bergantian untuk proses pelatihan dan validasi model. Pendekatan ini digunakan untuk mengurangi risiko *overfitting* serta meningkatkan kemampuan generalisasi model terhadap data baru [22].

Parameter yang diuji dalam proses *Grid Search* meliputi parameter C dengan nilai 0.1, 1, dan 10, parameter gamma dengan nilai *scale*, 0.1, dan 0.01, serta jenis kernel berupa *radial basis function* (RBF) dan linear. Parameter C digunakan untuk mengontrol tingkat toleransi kesalahan klasifikasi, sedangkan parameter gamma berpengaruh terhadap pola pembentukan *decision boundary* pada kernel RBF. Pengujian dua jenis kernel dilakukan untuk membandingkan kemampuan model dalam menangani pola linear maupun non-linear pada dataset PGK. Seluruh kombinasi parameter dievaluasi menggunakan metrik *accuracy* untuk menentukan konfigurasi terbaik berdasarkan hasil *cross-validation*.

Model dengan kombinasi parameter terbaik yang diperoleh dari proses *Grid Search* kemudian digunakan sebagai model akhir untuk proses pelatihan menggunakan data latih. Selanjutnya, model tersebut digunakan untuk melakukan prediksi terhadap data uji pada tahap evaluasi untuk mengukur performa klasifikasi model dalam memprediksi PGK.

2.5 Evaluation

Performa model dievaluasi dengan sejumlah indikator, meliputi *accuracy*, *precision*, *recall*, dan *F1-score* yang dihasilkan melalui *classification report*. Selain itu, pengujian juga memanfaatkan *confusion matrix* untuk menyajikan informasi yang lebih rinci terkait hasil klasifikasi, termasuk sebaran prediksi yang sesuai maupun yang tidak sesuai pada setiap kategori kelas [23].

Berdasarkan *confusion matrix*, dapat diketahui komponen *true positive*, *true negative*, *false positive*, serta *false negative*, sehingga penilaian terhadap kemampuan model dapat dilakukan secara lebih komprehensif [24]. Hasil pada tahap ini kemudian digunakan untuk

menilai efektivitas metode SVM dalam memprediksi PGK, sekaligus menjadi landasan dalam penyusunan kesimpulan penelitian.

2.6 Deployment

Pada tahap *deployment*, model SVM yang telah melalui proses pelatihan dan evaluasi diimplementasikan dalam bentuk aplikasi berbasis web sebagai prototipe sistem prediksi PGK. Model yang telah terbentuk disimpan dalam format *pickle* dengan bantuan pustaka *joblib* agar dapat dimuat kembali pada saat diperlukan tanpa harus melalui proses pelatihan ulang. Pengembangan aplikasi dilakukan dengan memanfaatkan *framework Gradio* untuk membangun antarmuka yang bersifat interaktif serta memudahkan pengguna dalam mengoperasikan sistem [25]. Melalui aplikasi tersebut, pengguna dapat memasukkan data klinis pasien sebagai *input*, yang kemudian diproses oleh model untuk menghasilkan keluaran berupa prediksi secara langsung.

Selanjutnya, aplikasi diintegrasikan dan dipublikasikan melalui *platform Hugging Face Spaces* sehingga dapat diakses secara daring. Tahap ini menekankan bahwa model yang dikembangkan tidak hanya dievaluasi dari sisi kinerja komputasional, tetapi juga dirancang agar memiliki nilai guna dalam praktik, khususnya sebagai alat bantu dalam mendukung proses pengambilan keputusan awal terkait risiko PGK. Tahap *deployment* berperan penting dalam menghubungkan hasil pengembangan model dengan penerapannya di lingkungan nyata.

3. Hasil dan Pembahasan

Bagian ini menyajikan hasil dari setiap tahapan penelitian serta pembahasan secara komprehensif terhadap temuan yang dihasilkan. Uraian diawali dengan hasil tahap *modelling* yang menjelaskan proses pembentukan model SVM beserta konfigurasi parameter terbaik yang diperoleh. Selanjutnya, disajikan hasil evaluasi yang memaparkan kinerja model berdasarkan berbagai metrik evaluasi, termasuk analisis *confusion matrix* untuk memberikan gambaran lebih mendalam terhadap kemampuan klasifikasi model. Pada bagian akhir, dibahas hasil tahap *deployment* yang menunjukkan implementasi model ke dalam aplikasi berbasis web serta fungsionalitas sistem dalam melakukan prediksi secara *real-time*. Pembahasan pada setiap bagian dilakukan secara analitis untuk menginterpretasikan hasil yang diperoleh serta mengaitkannya dengan tujuan penelitian.

3.1 Hasil Modelling

Tahap pemodelan menghasilkan model klasifikasi menggunakan algoritma *Support Vector Machine* (SVM). Dalam proses pengembangannya, dilakukan penyesuaian parameter menggunakan metode *GridSearchCV* untuk memperoleh konfigurasi model terbaik. Proses hyperparameter tuning dilakukan dengan menguji beberapa kombinasi parameter, yaitu nilai C {0.1, 1, 10}, nilai γ {scale, 0.1, 0.01}, serta jenis kernel {linear, RBF}. Pengujian kernel linear dan RBF dilakukan untuk membandingkan kemampuan model dalam menangani pola data linear maupun non-linear. Proses pencarian parameter terbaik dilakukan menggunakan skema *5-fold cross-validation*. Berdasarkan hasil optimasi yang ditunjukkan pada Tabel 3, diperoleh kombinasi parameter terbaik yaitu kernel RBF dengan nilai C sebesar 0.1 dan γ sebesar 0.1. Kombinasi parameter tersebut menghasilkan performa klasifikasi terbaik pada dataset PGK yang digunakan dalam penelitian ini.

Tabel 3. Parameter optimal hasil *hyperparameter tuning* algoritma SVM

Parameter	Nilai
C	0.1
Gamma	0.1
Kernel	'rbf'

Berdasarkan hasil pencarian parameter, diperoleh konfigurasi terbaik yang selanjutnya digunakan dalam proses pengembangan model. Dengan konfigurasi tersebut, model dibangun menggunakan data latih yang sebelumnya telah diproses melalui tahapan praproses dan penskalaan fitur, sehingga menghasilkan model klasifikasi yang siap digunakan untuk tahap prediksi. Setelah model terbentuk, dilakukan pengujian awal dengan menampilkan hasil prediksi terhadap sebagian data uji. Hasil pada 10 data pertama menunjukkan bahwa model mampu memetakan data ke dalam dua kategori, yaitu PGK dan non-PGK, sesuai dengan pola pembelajaran yang diperoleh selama proses pelatihan, sebagaimana ditunjukkan pada Tabel 4. Hal ini memberikan gambaran awal mengenai kemampuan model dalam menangkap pola pada data. Evaluasi lebih lanjut kemudian dilakukan pada tahap berikutnya untuk mengukur kinerja model secara kuantitatif menggunakan metrik yang telah ditentukan.

Tabel 4. Hasil prediksi dari 10 data pertama

Urutan Data	Hasil Prediksi
Data ke – 1	0
Data ke – 2	0
Data ke – 3	1
Data ke – 4	1
Data ke – 5	1
Data ke – 6	1
Data ke – 7	0
Data ke – 8	1
Data ke – 9	0
Data ke – 10	1

3.2 Hasil Evaluasi

Evaluasi dilakukan dengan menguji model SVM menggunakan data uji untuk menilai performa klasifikasinya. Model menghasilkan tingkat akurasi sebesar 98.75% pada data uji, yang menunjukkan bahwa sebagian besar data berhasil diklasifikasikan dengan tepat. Hasil evaluasi memperlihatkan bahwa nilai *precision*, *recall*, dan *F1-score* berada pada kisaran 97% hingga 100% untuk kedua kelas, yaitu non-PGK (0) dan PGK (1), sebagaimana ditunjukkan pada Tabel 5. Nilai tersebut menunjukkan bahwa model memiliki performa klasifikasi yang sangat baik dan relatif seimbang pada masing-masing kelas tanpa indikasi bias yang signifikan.

Hasil penelitian ini menunjukkan performa yang lebih baik dibandingkan beberapa penelitian sebelumnya pada kasus prediksi PGK. Penelitian oleh Qodri melaporkan bahwa metode *Random Forest* memperoleh akurasi sebesar 90.50%, *Naive Bayes* sebesar 94.21%, sedangkan SVM memperoleh akurasi sebesar 88.84% pada *dataset PGK UCI Repository* [25]. Penelitian lain oleh Paramita dan Prasetyaningtyas menunjukkan bahwa model SVM yang dioptimasi menggunakan *GridSearchCV* dan *SMOTE* menghasilkan akurasi sebesar 93% dengan *recall* sebesar 99% [26]. Jika dibandingkan dengan penelitian tersebut, model SVM pada penelitian ini menghasilkan akurasi yang lebih tinggi, yaitu sebesar 98.75%, sehingga menunjukkan bahwa optimasi parameter yang dilakukan memberikan pengaruh positif terhadap peningkatan performa klasifikasi.


Selain itu, penggunaan kernel RBF pada penelitian ini memungkinkan model menangani hubungan non-linear antar fitur dengan lebih baik dibandingkan pendekatan linear sederhana. Temuan ini memperlihatkan metode SVM memiliki potensi yang baik sebagai pendekatan klasifikasi pada data klinis, khususnya untuk prediksi PGK.

Walaupun tingginya nilai akurasi yang diperoleh perlu dianalisis lebih lanjut karena ukuran *dataset* yang relatif terbatas, yaitu sebanyak 400 data. *Dataset* dengan jumlah data yang kecil berpotensi menyebabkan model mengalami *overfitting*, dengan model mampu mengenali pola data latih dengan sangat baik tetapi kurang optimal ketika diterapkan pada data baru. Untuk meminimalkan risiko tersebut, penelitian ini menerapkan pembagian data menggunakan train-test split dengan proporsi 80:20 serta proses *5-fold cross-validation* pada tahap *hyperparameter tuning*. Pendekatan tersebut dilakukan untuk meningkatkan kemampuan generalisasi model dan menjaga konsistensi performa selama proses pelatihan dan pengujian. Namun demikian, potensi *overfitting* tetap menjadi perhatian sehingga pengujian pada *dataset* yang lebih besar dan lebih beragam perlu dilakukan pada penelitian selanjutnya untuk memastikan stabilitas model secara lebih komprehensif.

Tabel 5. Hasil evaluasi performa model SVM pada data uji

	<i>Precision</i>	<i>Recall</i>	<i>F1-Score</i>	<i>Support</i>
Non-PGK	97%	100%	98%	28
PGK	100%	98%	99%	52
<i>Accuracy</i>			98.75%	80
<i>Macro Average</i>	98%	99%	99%	80
<i>Weighted Average</i>	99%	99%	99%	80

Selain itu, evaluasi melalui *confusion matrix* menunjukkan bahwa dari total 80 data uji yang digunakan, sebanyak 28 data non-PGK berhasil diprediksi dengan benar sebagai non-PGK, sedangkan 51 data PGK berhasil diklasifikasikan secara tepat sebagai PGK. Model hanya menghasilkan satu kesalahan klasifikasi, yaitu satu data PGK yang diprediksi sebagai non-PGK (*false negative*). Tidak ditemukan kesalahan prediksi pada kelas non-PGK yang diklasifikasikan sebagai PGK (*false positive*). Hasil ini menunjukkan bahwa model memiliki kemampuan klasifikasi yang sangat baik dengan tingkat kesalahan yang relatif rendah. Namun demikian, keberadaan *false negative* tetap menjadi perhatian karena dalam ranah medis kesalahan tersebut berpotensi menyebabkan pasien PGK tidak terdeteksi pada tahap awal. Distribusi kesalahan yang sangat kecil juga mengindikasikan bahwa model tidak menunjukkan bias yang signifikan terhadap salah satu kelas, sehingga performa klasifikasi antar kelas cenderung seimbang. Sebaran hasil prediksi pada masing-masing kelas divisualisasikan melalui *confusion matrix* yang ditunjukkan pada Gambar 2.

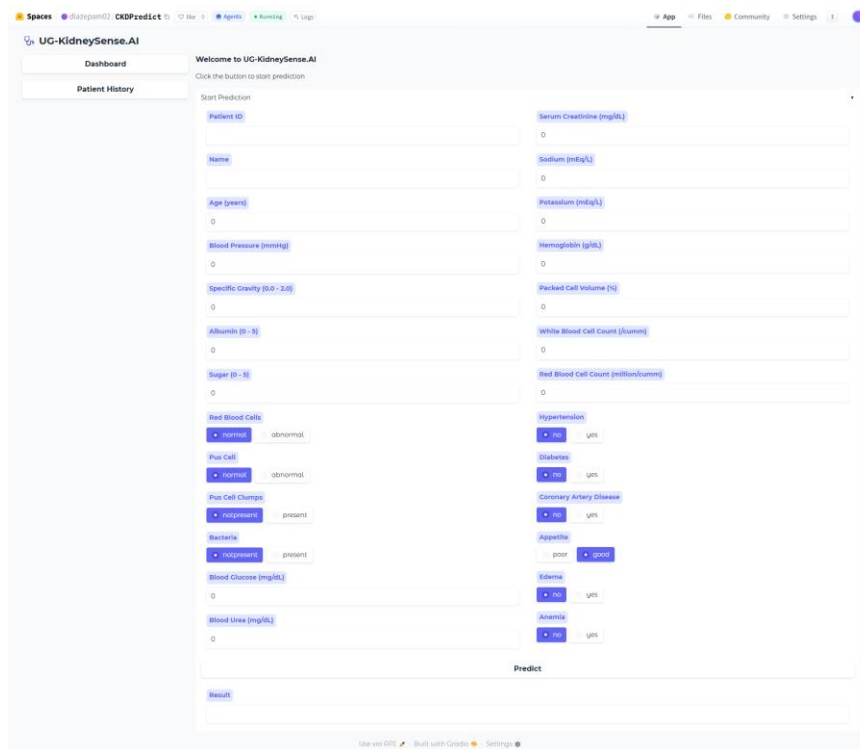


Gambar 2. Confusion matrix

3.3 Hasil Deployment

Tahap *deployment* menghasilkan implementasi model SVM ke dalam sebuah aplikasi berbasis web yang dikembangkan dengan *framework Gradio* serta dipublikasikan melalui *platform Hugging Face Spaces*. Aplikasi tersebut dirancang dengan antarmuka yang terorganisasi dan interaktif, sehingga pengguna dapat memasukkan berbagai data klinis pasien, seperti usia, tekanan darah, kadar kreatinin, dan indikator lainnya, sebagaimana ditampilkan pada Gambar 3.

Data yang dimasukkan kemudian diproses secara otomatis oleh model untuk menghasilkan keluaran berupa prediksi dalam waktu singkat. Selain fungsi utama tersebut, sistem juga dilengkapi dengan fitur *dashboard* serta *patient history* yang memungkinkan penyimpanan dan penelusuran kembali hasil prediksi pasien.



Gambar 3. Hasil *deployment*

Pengujian sistem pada tahap *deployment* ini dilakukan menggunakan dua data pasien *dummy*. Data pasien 1 dimasukkan melalui aplikasi berbasis web yang telah dikembangkan, mencakup berbagai parameter klinis seperti usia, tekanan darah, hemoglobin, kadar kreatinin, kadar ureum, natrium, kalium, serta indikator medis lainnya. Berdasarkan data yang dimasukkan, sistem memproses informasi tersebut menggunakan model SVM dan menghasilkan prediksi *High Risk of Chronic Kidney Disease*.

Selanjutnya, hasil prediksi model divalidasi oleh satu orang dokter spesialis penyakit dalam untuk mengevaluasi kesesuaian hasil klasifikasi sistem terhadap kondisi klinis pasien berdasarkan parameter medis yang digunakan pada *dataset*. Proses validasi dilakukan dengan memberikan hasil prediksi sistem beserta data pasien kepada validator untuk dibandingkan dengan hasil interpretasi medis secara independen. Indikator evaluasi pada tahap ini didasarkan pada kesesuaian antara hasil prediksi model dan penilaian pakar terhadap kategori pasien, yaitu PGK atau non-PGK. Pada contoh pengujian yang ditunjukkan pada Gambar 4, sistem memprediksi Pasien 1 sebagai kategori PGK dan hasil tersebut dinyatakan sesuai oleh dokter spesialis penyakit dalam.

Selain validasi pakar, performa model juga dievaluasi menggunakan metrik *accuracy*, *precision*, *recall*, *F1-score*, dan *confusion matrix* untuk mengukur kemampuan klasifikasi model secara komprehensif. Hasil evaluasi pada Tabel 5 dan Gambar 2 menunjukkan bahwa model mampu menghasilkan performa klasifikasi yang tinggi dengan distribusi kesalahan yang relatif rendah. Kombinasi evaluasi kuantitatif dan validasi pakar tersebut menunjukkan bahwa model yang dikembangkan tidak hanya memiliki performa yang baik secara komputasional, tetapi juga memiliki kesesuaian awal terhadap interpretasi klinis sehingga berpotensi digunakan sebagai alat bantu deteksi dini PGK.

The screenshot shows the UC-KidneySense.AI web application interface. It includes a 'Welcome to UC-KidneySense.AI' header and a 'Click the button to start prediction' instruction. The main area is divided into several sections for data entry and selection:

- Patient Information:** Patient ID (5123), Name (Amran), Age (57 years), Blood Pressure (90 mmHg), and Specific Gravity (1,010).
- Serum Creatinine (mg/dL):** 12
- Sodium (mEq/L):** 125
- Potassium (mEq/L):** 6,4
- Hemoglobin (g/dL):** 8,6
- Packed Cell Volume (%):** 26
- Albumin (0 - 5):** 3
- Sugar (0 - 5):** 2
- Red Blood Cells:** normal
- Pus Cell:** abnormal
- Pus Cell Clumps:** present
- Bacteria:** present
- Blood Glucose (mg/dL):** 175
- Blood Urea (mg/dL):** 308
- White Blood Cell Count (/cumm):** 5400
- Red Blood Cell Count (million/cumm):** 21
- Hypertension:** yes
- Diabetes:** yes
- Coronary Artery Disease:** no
- Appetite:** poor
- Edema:** yes
- Anemia:** yes

The **Predict** button is visible at the bottom right. Below the input fields, a **Result** section displays the prediction: "Prediction: High Risk of Chronic Kidney Disease".

Below the prediction, a summary table for **Pasien 1** is provided:

Pasien 1				
Usia	:	57 tahun	Berat jenis urine	: 1,010
Tekanan darah diastol	:	90 mmHg	Albumin	: +++
Hemoglobin	:	8,6 g/dL	Gula dalam urine	: ++
Hematokrit	:	26%	Eritrosit dalam urine	: normal
Red blood cell count	:	2,1 × 10 ⁹ /μL	Leukosit dalam urine	: abnormal
White blood cell count	:	5400 × 10 ³ /μL	Bakteri dalam urine	: iya
Gula darah sewaktu	:	175 mg/dL	Pus cell clumps	: iya
Blood urea nitrogen	:	308 mg/dL	Nafsu makan	: buruk
Serum kreatinin	:	12 mg/dL	Edema tungkai	: iya
Natrium	:	125 mmol/L	Hipertensi	: iya
Kalium	:	6,4 mmol/L	Coronary artery disease	: tidak
			Anemia	: iya
			Diabetes melitus	: iya

Below the table, a note states: "Berdasarkan hasil analisis terhadap data klinis dan parameter penunjang yang tersedia, pasien ini diklasifikasikan sebagai [PGK/ non-PGK]". A signature and date "20 Januari 2026" are present, along with the name "dr. Hadyanto Caputra, MARS, Sp.PD".

Gambar 4. Pengujian pada pasien 1

Pengujian selanjutnya dilakukan menggunakan data *dummy* Pasien 2 sebagai sampel uji tambahan untuk mengetahui konsistensi kinerja sistem dalam mengklasifikasikan kondisi pasien dengan karakteristik data yang berbeda. Berdasarkan data klinis yang dimasukkan ke dalam aplikasi, pasien *dummy* atas nama Anisa berusia 36 tahun memiliki parameter medis yang cenderung berada dalam rentang normal, seperti tekanan darah 80 mmHg, serum kreatinin 1 mg/dL, hemoglobin 15 g/dL, *packed cell volume* 45%, serta tidak terdapat riwayat hipertensi, diabetes, edema, maupun anemia. Setelah seluruh data diproses oleh model SVM, sistem menghasilkan prediksi *Low Risk of Chronic Kidney Disease*.

Hasil tersebut kemudian dibandingkan dengan validasi dari dokter spesialis penyakit dalam, yang menyatakan bahwa pasien tidak menunjukkan indikasi PGK. Kesesuaian antara hasil prediksi sistem dan penilaian pakar menunjukkan bahwa aplikasi tidak hanya mampu mendeteksi pasien dengan risiko tinggi PGK, tetapi juga dapat mengenali pasien dengan

risiko rendah secara tepat. Hasil pengujian pada Pasien 2 pada Gambar 5 semakin memperkuat bahwa sistem yang dikembangkan memiliki performa yang baik dan berpotensi digunakan sebagai alat bantu skrining awal PGK secara akurat.

Welcome to UG-KidneySense.AI
Click the button to start prediction

Start Prediction

Patient ID: 4321
Name: Anisa
Age (years): 36
Blood Pressure (mmHg): 80
Specific Gravity (0.0 - 2.0): 1,020
Albumin (0 - 5): 0

Serum Creatinine (mg/dL): 1
Sodium (mEq/L): 140
Potassium (mEq/L): 4,5
Hemoglobin (g/dL): 15
Packed Cell Volume (%): 45
White Blood Cell Count (/cumm): 5500

Sugar (0 - 5): 0
Red Blood Cells: normal
Pus Cell: normal
Pus Cell Clumps: notpresent
Bacteria: notpresent
Blood Glucose (mg/dL): 80
Blood Urea (mg/dL): 18

Red Blood Cell Count (million/cumm): 6,5
Hypertension: no
Diabetes: no
Coronary Artery Disease: no
Appetite: good
Edema: no
Anemia: no

Predict

Result: Prediction: Low Risk of Chronic Kidney Disease

Pasien 2

Usia	: 36 tahun	Berat jenis urine	: 1,020
Tekanan darah diastol	: 80 mmHg	Albumin	: -
Hemoglobin	: 15 g/dL	Gula dalam urine	: -
Hematokrit	: 45%	Eritrosit dalam urine	: normal
Red blood cell count	: $6,5 \times 10^9/\mu\text{L}$	Leukosit dalam urine	: normal
White blood cell count	: $5500 \times 10^9/\mu\text{L}$	Bakteri dalam urine	: tidak
Gula darah sewaktu	: 80 mg/dL	Pus cell clumps	: tidak
Blood urea nitrogen	: 18 mg/dL	Nafsu makan	: baik
Serum kreatinin	: 1 mg/dL	Edema tungkai	: tidak
Natrium	: 140 mmol/L	Hipertensi	: tidak
Kalium	: 4,5 mmol/L	Coronary artery disease	: tidak
		Anemia	: tidak
		Diabetes melinus	: tidak

Berdasarkan hasil analisis terhadap data klinis dan parameter penunjang yang tersedia, pasien ini diklasifikasikan sebagai [PGK/ non-PGK]

20 Januari 2026

dr. Hadyanto Caputra, MARS, Sp.PD

Gambar 5. Pengujian pada pasien 2

Setelah data pasien dimasukkan ke sistem, pengguna juga dapat melihat *record* data pasien yang sudah disimpan ke sistem menggunakan fitur *Patient History* yang ditunjukkan pada Gambar 6. Pada halaman *Patient History* disajikan informasi ID pasien, nama pasien, umur pasien, dan hasil prediksi yang dihasilkan oleh sistem. Pada halaman tersebut juga disediakan tombol *Delete* yang dapat digunakan untuk menghapus *record* pasien berdasarkan ID pasien.

UG-KidneySense.AI

Dashboard

Patient History

Patient ID	Name	Age	Result
5123	Amran	57	High Risk of Chronic Kidney Disease
4321	Anisa	36	Low Risk of Chronic Kidney Disease
3512	Sumarta	68	Low Risk of Chronic Kidney Disease
2112	Astuti	45	High Risk of Chronic Kidney Disease

Delete Record

Enter Patient ID to Delete

Delete

Gambar 6. Halaman *patient history*

4. Kesimpulan

Penelitian ini berhasil mengembangkan model prediksi PGK menggunakan algoritma SVM dengan pendekatan optimasi parameter melalui *GridSearchCV*. Berdasarkan hasil pengujian, model mampu mencapai akurasi sebesar 98.75% dengan nilai *precision*, *recall*, dan *F1-score* yang tinggi. Hasil tersebut menunjukkan bahwa model memiliki kemampuan klasifikasi yang baik dan relatif seimbang dalam membedakan pasien PGK dan non-PGK.

Kontribusi utama penelitian ini terletak pada penerapan optimasi parameter SVM secara sistematis untuk meningkatkan performa klasifikasi pada kasus prediksi PGK, serta integrasi model ke dalam aplikasi berbasis web menggunakan *Gradio* dan *Hugging Face Spaces* sebagai bentuk implementasi dalam mendukung deteksi dini. Selain itu, hasil validasi awal oleh dokter spesialis penyakit dalam menunjukkan bahwa keluaran sistem memiliki kesesuaian dengan interpretasi medis, sehingga model memiliki potensi sebagai alat bantu pendukung keputusan pada tahap awal identifikasi PGK.

Meskipun model menunjukkan performa yang tinggi, penelitian ini masih memiliki keterbatasan pada jumlah dan variasi *dataset* yang digunakan serta belum dilakukan perbandingan dengan beberapa algoritma ML lainnya. Oleh karena itu, penelitian selanjutnya disarankan menggunakan *dataset* yang lebih besar dan beragam untuk meningkatkan kemampuan generalisasi model. Selain itu, evaluasi dapat dikembangkan dengan membandingkan performa SVM terhadap metode lain seperti *Random Forest*, *Gradient Boosting*, dan *Neural Network*. Pengembangan lanjutan juga dapat dilakukan melalui penerapan seleksi fitur berbasis *embedded method* atau *wrapper method*, optimasi model yang lebih mendalam menggunakan pendekatan *ensemble learning*, serta integrasi dengan sistem rekam medis elektronik untuk mendukung implementasi pada lingkungan klinis yang lebih luas.

Ucapan Terima Kasih

Penulis mengucapkan terima kasih kepada Fakultas Kedokteran Universitas Gunadarma atas dukungan akademik dan fasilitas penelitian yang diberikan selama proses pelaksanaan penelitian. Penulis juga menyampaikan apresiasi kepada seluruh pihak yang telah membantu dalam penyelesaian penelitian ini.

Pernyataan

Kontribusi Penulis. R.D.S.: konseptualisasi penelitian, perancangan metode, implementasi program, analisis data, penulisan draf awal. D.H.W.: pengumpulan data, validasi eksperimen, analisis hasil penelitian, peninjauan literatur. B.G.: evaluasi hasil, interpretasi data medis, peninjauan dan penyuntingan naskah. H.C.: supervisi aspek klinis penelitian, validasi metodologi, peninjauan akhir naskah. W.S.: pengolahan data, visualisasi hasil, penyuntingan naskah. R.F.E.S.: supervisi penelitian, pengawasan proyek, koordinasi tim penelitian, persetujuan akhir naskah.

Pendanaan. Penelitian ini didanai secara mandiri oleh penulis tanpa dukungan dana dari lembaga, institusi, atau pihak eksternal mana pun.

Konflik Kepentingan. Penulis menyatakan tidak terdapat konflik kepentingan terkait publikasi artikel ini.

Ketersediaan Data. *Dataset* yang digunakan dalam penelitian ini adalah *Chronic Kidney Disease Dataset* yang bersumber dari *UCI Machine Learning Repository* dan tersedia untuk diakses secara publik melalui tautan berikut: <https://doi.org/10.24432/C5G020>.

Penggunaan Kecerdasan Buatan (AI). Penulis menyatakan bahwa alat berbasis kecerdasan buatan (AI) digunakan dalam proses penelitian dan penyusunan naskah ini, terutama untuk

membantu pencarian referensi, penyuntingan bahasa, analisis pendukung, dan bantuan pemrograman. Penggunaan AI dilakukan sebagai alat bantu untuk meningkatkan efisiensi dan kualitas penulisan, tanpa menggantikan proses analisis ilmiah dan interpretasi hasil oleh penulis. Seluruh isi, validitas data, interpretasi hasil, dan kesimpulan dalam naskah ini sepenuhnya menjadi tanggung jawab penulis.

Daftar Referensi

- [1] C. P. Kovesdy, "Epidemiology of chronic kidney disease: An update 2022," *Kidney Int. Suppl.*, vol. 12, no. 1, pp. 7–11, Apr. 2022, doi: 10.1016/j.kisu.2021.11.003.
- [2] L. Deng *et al.*, "Global, regional, and national burden of chronic kidney disease and its underlying etiologies from 1990 to 2021: A systematic analysis for the Global Burden of Disease Study 2021," *BMC Public Health*, vol. 25, no. 1, Art. no. 636, Feb. 2025, doi: 10.1186/s12889-025-21851-z.
- [3] N. M. Hustrini, E. Susalit, and J. I. Rotmans, "Prevalence and risk factors for chronic kidney disease in Indonesia: An analysis of the National Basic Health Survey 2018," *J. Glob. Health*, vol. 12, Art. no. 04074, Oct. 2022, doi: 10.7189/jogh.12.04074.
- [4] G. Kaur and V. Patney, "Progression of CKD and uremic symptoms," in *Approaches to Chronic Kidney Disease*, J. McCauley, S. M. Hamrahian, and O. H. Maarouf, Eds. Cham: Springer Int. Publ., 2022, pp. 69–85, doi: 10.1007/978-3-030-83082-3_5.
- [5] S. Wang *et al.*, "Chronic kidney disease: Bridging conventional therapeutics and emerging molecular innovations," *Prog. Microbes Mol. Biol.*, vol. 8, no. 1, Aug. 2025, doi: 10.36877/pmmb.a0000468.
- [6] R. M. Gama, K. Griffiths, R. P. Vincent, A. M. Peters, and K. Bramham, "Performance and pitfalls of the tools for measuring glomerular filtration rate to guide chronic kidney disease diagnosis and assessment," *J. Clin. Pathol.*, vol. 76, no. 7, pp. 442–449, Jul. 2023, doi: 10.1136/jcp-2023-208887.
- [7] R. Hasan, I. Ahmed, M. Hasan, A. A. Abir, S. Md. R. Islam, and S. M. A. Ullah, "Prediction of chronic kidney disease – a machine learning-based approach," in *Proc. Int. Conf. Artificial Intelligence for Innovations in Healthcare Industries (ICAIIHI)*, Raipur, India, Dec. 2023, pp. 1–7, doi: 10.1109/ICAIIHI57871.2023.10489799.
- [8] T. Thangarasan, B. Jai Kumar, S. Jeelan, S. R. Reddy, and B. Manohar, "AI supported chronic kidney disease prediction using machine learning classification techniques," in *Proc. 2nd Int. Conf. New Frontiers in Communication, Automation, Management and Security (ICCAMS)*, Bangalore, India, Jul. 2025, pp. 1–6. doi: 10.1109/ICCAMS65118.2025.11234089.
- [9] Md. S. Al Huda, E. Kanon, Md. S. K. Pappo, Md. A. Ali, and N. Ahmed, "NefroAI: An explainable and real-time framework for predicting chronic kidney disease using diverse machine learning models and different feature selection techniques," *IEEE Access*, vol. 14, pp. 10939–10976, 2026, doi: 10.1109/ACCESS.2025.3649006.
- [10] N. Bhaskar and M. Suchetha, "A computationally efficient correlational neural network for automated prediction of chronic kidney disease," *IRBM*, vol. 42, no. 4, pp. 268–276, Aug. 2021, doi: 10.1016/j.irbm.2020.07.002.
- [11] J. Wang, "A fusion kernel in SVM and improved evolutionary algorithm in feature selection for Parkinson's disease detection," in *Proc. 3rd Int. Conf. Artificial Intelligence, Automation, and High-Performance Computing (AIAHPC 2023)*, D. A.

- Karras and S. X. Yang, Eds., SPIE, Jul. 2023, Art. no. 127172G, doi: 10.1117/12.2684724.
- [12] X. Zhipeng, M. A. A. Aziz, and N. A. Razak, "Performance evaluation of support vector machine algorithm in object classification using different preprocessing methods," in *Proc. 2024 IEEE Int. Conf Automatic Control and Intelligent Systems (I2CACIS)*, Shah Alam, Malaysia, Jun. 2024, pp. 169–174, doi: 10.1109/I2CACIS61270.2024.10649625.
- [13] L. Rubini, P. Soundarapandian, and P. Eswaran, "Chronic kidney disease," *UCI Machine Learning Repository*, 2015, doi: 10.24432/C5G020.
- [14] M. J. Nodeh, M. H. Calp, and İ. Şahin, "Analyzing and processing of supplier database based on the cross-industry standard process for data mining (CRISP-DM) algorithm," in *Artificial Intelligence and Applied Mathematics in Engineering Problems*, D. Hemanth and U. Kose, Eds., *Lecture Notes on Data Engineering and Communications Technologies*, vol. 43. Cham, Switzerland: Springer, 2020, pp. 544 – 558, doi: 10.1007/978-3-030-36178-5_44.
- [15] A. Purbasari, F. R. Rinawan, A. Zulianto, A. I. Susanti, and H. Komara, "CRISP-DM for data quality improvement to support machine learning of stunting prediction in infants and toddlers," in *Proc. 2021 8th Int. Conf. Adv. Informatics: Concepts, Theory Appl. (ICAICTA)*, Bandung, Indonesia, Sep. 2021, pp. 1–6, doi: 10.1109/ICAICTA53211.2021.9640294.
- [16] B. Liu, Y. Lu, Y. Geng, Y. Pang, and Z. Zhu, "Current status and progress in research on postoperative acute kidney injury," *Chin. J. Clin. Res.*, vol. 37, no. 9, pp. 1438–1442, Sept. 2024, doi: 10.13429/j.cnki.cjcr.2024.09.025.
- [17] A. M. Sharifnia, D. E. Kpormegbey, D. K. Thapa, and M. Cleary, "A primer of data cleaning in quantitative research: handling missing values and outliers," *J. Adv. Nurs.*, vol. 82, no. 1, pp. 970–975, Jan. 2026, doi: 10.1111/jan.16908.
- [18] J. Sukhbaatar, B. Zagd, and N. Jambaljav, "Detection of point outliers in meteorological data (case study: Ulaanbaatar, Mongolia)," in *Advances in Intelligent Information Hiding and Multimedia Signal Processing*, J.-S. Pan, J. Li, K. H. Ryu, Z. Meng, and A. Klasnja-Milicevic, Eds., Smart Innovation, Systems and Technologies, vol. 212. Singapore: Springer, 2021, pp. 68–75, doi: 10.1007/978-981-33-6757-9_9.
- [19] K. Kim and B. Jang, "The effect of data split on correlation errors with respect to independent validation data," in *Proc. 20th Int. Topical Meeting Nucl. Reactor Thermal Hydraulics (NURETH-20)*, Washington, D.C., USA, Aug. 2023, pp. 2764–2771, doi: 10.13182/NURETH20-41342.
- [20] H. Nasir, A. Pandita, C. N. B. Nasir, and N. K. Ojha, "Significance of fairly distributed instances and optimal ratio for validation set in machine learning," in *International Conference on Innovation, Sustainability, and Applied Sciences (ICISAS 2023)*, C. Pon Selvan, N. Sehgal, S. Ruhela, and N. U. Rizvi, Eds., Signals and Communication Technology. Cham, Switzerland: Springer, 2025, pp. 641–647, doi: 10.1007/978-3-031-68952-9_83.
- [21] A. Shmilovici, "Support vector machines," in *Machine Learning for Data Science Handbook*, L. Rokach, O. Maimon, and E. Shmueli, Eds. Cham: Springer Int. Publ., 2023, pp. 93–110, doi: 10.1007/978-3-031-24628-9_6.
- [22] M. A. Widyananda and I. Palupi, "Implementation of the spiral optimization algorithm in the support vector machine (SVM) classification method (case study: diabetes

- prediction),” in *Proc. 2021 Int. Conf. Adv. Data Sci., E-learn. Inf. Sys. (ICADEIS)*, Bali, Indonesia, Oct. 2021, pp. 1–6, doi: 10.1109/ICADEIS52521.2021.9701953.
- [23] P. Ansah *et al.*, “Precision medicine in diabetes: A machine learning model for diabetic foot ulcer prediction using Keras TensorFlow,” in *Proc. 2024 1st Int. Conf. Cogn., Green and Ubiquitous Comput. (IC-CGU)*, Bhubaneswar, India, Mar. 2024, pp. 1–6, doi: 10.1109/IC-CGU58078.2024.10530735.
- [24] C. S. Hong and T. G. Oh, “TPR-TNR plot for confusion matrix,” *Commun. Stat. Appl. Methods*, vol. 28, no. 2, pp. 161–169, Mar. 2021, doi: 10.29220/CSAM.2021.28.2.161.
- [25] K. N. Qodri, M. R. Fikri, and L. Ardi, “Analytical prediction for chronic kidney disease: A comparison of machine learning methods,” *JKTi: Jurnal Keilmuan Teknologi Informasi*, vol. 1, no. 1, pp. 15–22, Jul. 2025, doi: 10.61902/jkti.v1i1.1686.
- [26] C. Paramita and W. Prasetyaningtyas, “Enhanced chronic kidney disease prediction using optimized support vector machine with hyperparameter tuning and SMOTE,” *Rabit: Jurnal Teknologi dan Sistem Informasi Univrab*, vol. 11, no. 1, pp. 964–978, Jan. 2026, doi: 10.36341/rabit.v11i1.7179.