

Machine Learning

## Pengembangan *Machine Learning* dalam Preskripsi Obat Pasien untuk Mengurangi Kesalahan Penggunaan Obat dan Mencegah Kerugian Rumah Sakit akibat Pemakaian Obat yang Tidak Tepat

*Muh Ikbal Sodikin* \*, *Ema Utami*

*Magister Informatika, Universitas Amikom Yogyakarta, Yogyakarta, Indonesia*

### INFORMASI ARTIKEL

Diterima Redaksi: 07 Mei 2025  
Revisi Akhir: 30 Juni 2025  
Diterbitkan *Online*: 30 Juni 2025

### KATA KUNCI

Polypharmacy  
Support Vector Machine (SVM)  
Machine Learning in Healthcare

### KORESPONDENSI (\*)

Phone: -  
E-mail: [Muh.ikbalsodikin@students.amikom.ac.id](mailto:Muh.ikbalsodikin@students.amikom.ac.id)

### A B S T R A C T

Prescribing medications to patients with chronic diseases or complications such as diabetes and stroke requires special attention, especially when patients are co-treated by an internist and a neurologist. The risk of polypharmacy and inappropriate drug administration can adversely affect patient health. This study uses the Support Vector Machine (SVM) algorithm to classify and analyze drug administration patterns in patients with chronic diseases or complications. The data used includes patient medication history, diagnosis, and prescriptions from various specialists. The SVM algorithm was implemented to identify potential overlaps or similarities in drug administration. The results of the analysis using SVM successfully identified drug administration patterns that could potentially lead to polypharmacy. The model was able to detect the similarity of drug content with 92% accuracy. The results showed that 15% of the total prescriptions analyzed had the potential for overlapping drug content. The use of the SVM algorithm in the analysis of drug prescribing proved effective in reducing the risk of polypharmacy and inappropriate drug administration in patients with chronic diseases or complications. The implementation of this machine learning-based system can help doctors make more informed prescribing decisions, improve patient safety, and optimize treatment outcomes.

### PENDAHULUAN

Kesalahan dalam preskripsi obat merupakan masalah serius yang dapat menyebabkan efek samping berbahaya bagi pasien. Untuk meningkatkan keselamatan pasien dan hasil klinis dengan mengurangi risiko kesalahan penulisan resep, kami menguji keakuratan sistem pendukung keputusan hybrid clinical dalam memprioritaskan pemeriksaan resep [1]. Untuk meningkatkan keamanan pengobatan di rumah sakit dengan mengintegrasikan metode rekayasa keselamatan dengan machine learning (ML). Masalah kesalahan pengobatan yang terus-menerus menjadi penyebab utama kerugian pasien yang dapat dihindari [2]. Perkembangan teknologi machine learning telah menawarkan solusi menjanjikan untuk mengatasi masalah ini. Algoritma machine learning yang sering digunakan, seperti Naive Bayes, Decision Tree, dan Logistic Regression, memiliki kelemahan dalam menangani data nonlinear dan kompleks yang sering ditemui dalam data kesehatan. Salah satu algoritma yang dapat menjadi solusi adalah Support Vector Machine (SVM). SVM adalah algoritma supervised learning yang terbukti efektif dalam menangani data nonlinear dan memberikan akurasi tinggi, termasuk di bidang kesehatan. SVM memiliki kemampuan yang efektif dalam menangani data nonlinear, mekanisme pencegahan overfitting, dan akurasi tinggi dalam berbagai domain, termasuk kesehatan. Dalam konteks kesalahan preskripsi obat, SVM dapat dilatih untuk mengklasifikasikan resep obat berisiko menimbulkan kesalahan. Penelitian ini bertujuan mengkaji penggunaan algoritma SVM untuk mengurangi kesalahan preskripsi obat, dengan harapan dapat memberikan wawasan berharga bagi praktisi dan peneliti. pengobatan medication errors (MEs) di unit perawatan intensif neonatal (NICU) dan potensi artificial intelligence (AI) dan Machine Learning (ML) untuk memprediksi dan mengurangi kesalahan-kesalahan ini [3]. Dampak sistem entri pesanan dokter terkomputerisasi (CPOE) terhadap kesalahan

pengobatan dan hasil klinis, dengan menekankan peran model Machine Learning (ML) dalam memprediksi kesalahan pemesanan obat. Menganalisis kumpulan data lebih dari 5,8 juta pesanan obat, penelitian ini membandingkan berbagai teknik ML, dengan decision trees yang ditingkatkan gradien muncul sebagai model yang paling efektif, mencapai area di bawah kurva karakteristik operasi penerima (AUROC) sebesar 0,7968 [4].

## TINJAUAN PUSTAKA

Kesalahan dalam persepsian obat masih menjadi salah satu penyebab utama insiden keselamatan pasien di fasilitas pelayanan kesehatan, baik di tingkat primer maupun rumah sakit rujukan. Kesalahan ini dapat berupa dosis yang tidak sesuai, interaksi obat yang berbahaya, pemberian obat yang tidak diperlukan, hingga pengabaian kondisi komorbid pasien yang seharusnya dipertimbangkan dalam pengambilan keputusan klinis. Dalam beberapa kasus, kesalahan preskripsi dapat menyebabkan kejadian yang fatal, khususnya bagi kelompok pasien dengan risiko tinggi seperti lansia, anak-anak, dan pasien dengan penyakit kronis. Oleh karena itu, dibutuhkan sistem yang mampu mendeteksi dan mencegah kesalahan preskripsi sebelum obat diberikan kepada pasien.

Kecerdasan buatan (AI) telah menunjukkan potensi besar dalam mengatasi tantangan ini dengan menyediakan pendekatan berbasis data untuk mendukung proses pengambilan keputusan klinis. Salah satu penelitian awal yang relevan dilakukan oleh Corny et al., yang mengembangkan sistem pendukung keputusan klinis berbasis machine learning yang dirancang untuk mengidentifikasi kesalahan preskripsi secara otomatis [1]. Sistem ini memanfaatkan data dari Electronic Health Records (EHR) untuk mendeteksi anomali dalam resep yang diberikan oleh dokter. Melalui proses pembelajaran dari data historis, sistem dapat mengenali pola preskripsi yang tidak lazim atau bertentangan dengan standar klinis. Hasil penelitian menunjukkan bahwa sistem ini dapat memberikan peringatan dini kepada tenaga medis terhadap kemungkinan kesalahan yang berpotensi membahayakan pasien, sekaligus meningkatkan efisiensi waktu dalam praktik klinis.

Sejalan dengan itu, penelitian oleh Jia et al. memperluas pemanfaatan machine learning dengan membangun kerangka kerja keselamatan pengobatan yang berorientasi pada pasien [2]. Framework yang dikembangkan ini menggabungkan data riwayat kesehatan pasien dengan aturan klinis berbasis bukti untuk mengidentifikasi preskripsi yang memiliki risiko tinggi. Fokus utama dari pendekatan ini adalah peningkatan kualitas pengambilan keputusan di lingkungan rumah sakit yang dinamis, kompleks, dan sering kali padat oleh beban kerja tinggi. Sistem ini terbukti mampu menyaring preskripsi yang tidak sesuai secara otomatis dan memberikan dukungan kepada dokter dalam memilih alternatif terapi yang lebih aman. Pendekatan ini sekaligus mengurangi ketergantungan pada penilaian subjektif dan meningkatkan konsistensi dalam praktik pengobatan berbasis data.

Penelitian lebih lanjut dilakukan oleh Yalçın et al. yang memfokuskan penerapan AI di lingkungan Neonatal Intensive Care Unit (NICU) yang sangat sensitif dan memiliki kompleksitas tinggi [3]. Mereka membangun model prediktif yang dapat mendeteksi kesalahan preskripsi pada bayi baru lahir, dengan mempertimbangkan variabel temporal serta karakteristik unik masing-masing pasien seperti berat badan lahir, usia gestasi, dan parameter fisiologis lainnya. Sistem ini dirancang untuk merespons secara real-time, memberikan notifikasi risiko kepada tenaga medis jika terdeteksi adanya deviasi dari standar persepsian yang telah divalidasi. Temuan mereka menunjukkan bahwa penerapan teknologi ini secara signifikan dapat mengurangi insiden kesalahan dan mendukung pengambilan keputusan yang cepat dan tepat dalam situasi kritis.

Selain penggunaan model prediktif, pendekatan lain dilakukan oleh King et al. yang menggunakan teknik pembelajaran terawasi (supervised learning) untuk mengenali pola preskripsi yang tidak sesuai dalam sistem EHR [4]. Model ini dilatih menggunakan data historis yang menghubungkan antara kondisi klinis pasien dengan jenis obat yang diberikan. Dengan kemampuan ini, sistem dapat mengenali hubungan tidak logis antara diagnosis dan terapi obat yang direkomendasikan. Model juga mampu mengantisipasi kesalahan sejak awal, sehingga membantu tenaga medis mencegah pemberian resep yang tidak tepat tanpa mengganggu alur kerja yang telah ada. Hal ini sangat penting untuk menjaga integrasi sistem ke dalam praktik klinis sehari-hari.

Sementara itu, Luz et al. melakukan kajian sistematis terhadap berbagai pendekatan machine learning yang digunakan dalam pemrosesan data rekam medis elektronik, dengan fokus pada aplikasi dalam diagnosis dan pengobatan [5]. Mereka menyoroti berbagai tantangan yang harus diatasi dalam pengembangan sistem berbasis AI, seperti kualitas dan kelengkapan data, interoperabilitas antar sistem informasi kesehatan, serta kebutuhan akan interpretabilitas model agar

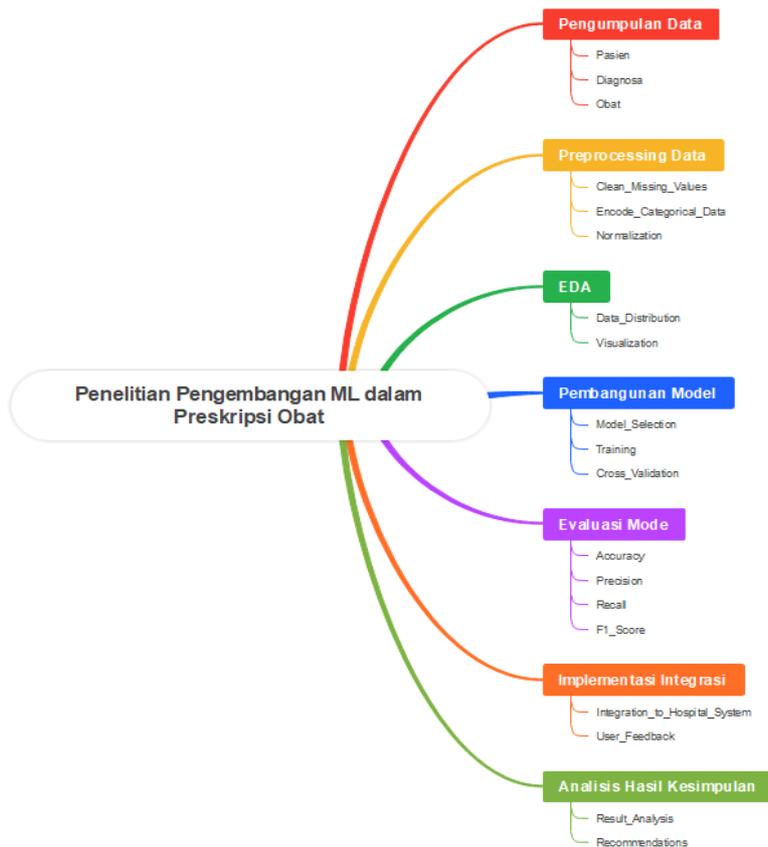
dapat dipahami dan dipercaya oleh tenaga medis. Kajian ini juga menekankan pentingnya kerja sama multidisipliner antara ilmuwan data dan profesional medis dalam memastikan bahwa model AI tidak hanya akurat dari sisi teknis, tetapi juga relevan dan aplikatif dalam konteks klinis.

Dari tinjauan terhadap berbagai penelitian di atas, dapat disimpulkan bahwa integrasi teknologi kecerdasan buatan dalam sistem preskripsi obat memiliki potensi besar untuk meningkatkan keselamatan pasien, mengurangi beban kerja tenaga medis, dan mendorong efisiensi pelayanan kesehatan secara keseluruhan. Pendekatan berbasis data memungkinkan deteksi dini terhadap kesalahan preskripsi dan menyediakan rekomendasi berbasis evidensi klinis. Namun, untuk dapat diimplementasikan secara efektif, sistem-sistem ini memerlukan dukungan infrastruktur data yang memadai, standar interoperabilitas yang jelas, serta pelatihan dan kesiapan tenaga medis dalam mengadopsi teknologi baru. Dengan dukungan regulasi dan kebijakan yang tepat, teknologi AI dapat menjadi komponen integral dalam sistem pelayanan kesehatan yang lebih cerdas dan aman..

## METODOLOGI

Penelitian ini akan menggunakan rekam medik elektronik pasien dalam pemberian resep obat pasien yang di ambil dari dua poliklinik yang berbeda karena pasien dilakukan rawat bersama antara poliklinik penyakit dalam dan poliklinik syaraf, dimana pasien tersebut di tangani oleh dua dokter spesialis penyakit dalam dan dokter spesialis syaraf sebagai input untuk melatih algoritma Support Vector Machine (SVM) untuk mengklasifikasi dalam perawatan pasien apakah ada indikasi penggunaan obat yang sama antar kedua poliklinik penyakit dalam dan poliklinik syaraf. Algoritma Support Vector Machine (SVM) digunakan untuk analisis data dalam manajemen dosis obat, memberikan informasi tentang jenis obat, dosis, diagnosis pasien. Perkembangan dan regulasi hukum terkait Rekam Medis Elektronik (EMR) di Indonesia, serta menekankan pentingnya EMR dalam meningkatkan efisiensi dan efektivitas layanan kesehatan, dengan Rekam Kesehatan Elektronik (EHR) untuk meningkatkan aksesibilitas dan keamanan data [5].

Menggunakan Support Vector Machines (SVM) dapat memungkinkan identifikasi komponen individual yang mungkin tidak terlihat menggunakan metode klasifikasi tradisional. Oleh karena itu, diharapkan bahwa penelitian ini akan memberikan kontribusi yang signifikan untuk mengurangi jumlah penolakan obat resep yang berpotensi membahayakan pasien. Penggunaan machine learning (ML) dengan sistem pendukung keputusan klinis (CDSS) dalam perawatan kesehatan, yang menekankan potensinya untuk meningkatkan pengambilan keputusan, meningkatkan akurasi diagnostik, dan mengoptimalkan perawatan pasien [6]. untuk menghindari terjadinya polifarmasi, karena dampak polifarmasi, termasuk masalah kesehatan dan sosial yang mungkin timbul dampak dari polifarmasi bagi kesehatan dan penyembuhan pasien mencakup berbagai hasil kesehatan yang merugikan, seperti frailty, malnutrisi, dan beberapa area penyakit kronis. Namun, bukti untuk efek samping obat yang merugikan dan reaksi obat yang merugikan bersifat bertentangan, yang mungkin mencerminkan perbedaan dalam penggunaan polifarmasi yang tepat versus tidak tepat [7]. Untuk mencegah reaksi obat yang merugikan Adverse drug reactions (ADRs) atau reaksi obat yang merugikan dan meningkatkan keselamatan pasien pada pasien lanjut usia melalui peninjauan dan manajemen obat yang cermat [8]. dengan menggunakan data dari rekam medik elektronik sangat membantu dalam pengambilan data pasien seperti resep obat dan diagnosa pasien serta catatan medis pasien, yang sangat berpengaruh dengan pengolahan data menggunakan Machine Learning karena proses pengambilan data yang cepat yang didapat dari database pasien di rumah sakit.



Gambar.1 Data Flowchart Penelitian

Untuk melakukan penelitian ini, kita dapat menggunakan algoritma Support Vector Machine (SVM) untuk melakukan klasifikasi data pasien berdasarkan poliklinik yang pasien kunjungi yaitu poliklinik penyakit dalam dan poliklinik syaraf.

1. Fungsi Hyperplane

Hyperplane dalam ruang n-dimensi dapat dinyatakan sebagai:

$$w \cdot x + b = 0 \tag{1}$$

di mana

w adalah vektor bobot (weight vector).

x adalah vektor fitur (feature vector).

b adalah bias atau intercept.

2. Kondisi klasifikasi

Untuk klasifikasi biner, data dikelompokkan berdasarkan posisi relatif mereka terhadap hyperplane

$$\text{Jika } w \cdot x + b \geq 0, \text{ maka } y = 1 \tag{2}$$

$$\text{Jika } w \cdot x + b < 0, \text{ maka } y = -1 \tag{3}$$

3. Fungsi Tujuan

SVM mencari hyperplane yang memaksimalkan margin (jarak terdekat antara data dari kedua kelas ke hyperplane), dengan rumus

$$\min \frac{1}{2} \|w\|^2 \tag{4}$$

dengan syarat

$$y_i (w \cdot x_i + b) \geq 1 \text{ untuk semua } i \tag{5}$$

Di sini,  $y_i$  adalah label dari sampel  $i$ , dan  $x_i$  adalah vektor fitur dari sampel  $i$ .

4. Penanganan Data Tidak Linear (Kernel Trick)

Ketika data tidak dapat dipisahkan secara linear, SVM menggunakan kernel untuk memetakan data ke ruang dimensi yang lebih tinggi di mana data dapat dipisahkan secara linear. Kernel yang umum digunakan termasuk

$$\text{Linear Kernel } K(x_i, x_j) = x_i \cdot x_j \tag{6}$$

$$\text{Polynomial Kernel } K(x_i, x_j) = (x_i \cdot x_j + c)^d \tag{7}$$

$$\text{Gaussian (RBF) Kernel } K(x_i, x_j) = \exp \tag{8}$$

5. Dalam kasus di mana data tidak sepenuhnya dapat dipisahkan, SVM memperkenalkan faktor regularisasi C untuk mengendalikan trade-off antara margin yang lebar dan kesalahan klasifikasi minimal  
 Dengan syarat

$$y_i(w \cdot x_i + b) \geq 1 - \xi_i \tag{9}$$

di mana  $\xi_i$  adalah slack variable yang memungkinkan pelanggaran margin.

6. Prediksi

Setelah model dilatih, prediksi untuk sampel baru x dilakukan dengan menghitung

$$y = \text{sign}(w \cdot x + b) \tag{10}$$

Jika  $y \geq 0$ , maka sampel diklasifikasikan sebagai kelas positif jika  $y < 0$  maka sampel diklasifikasikan sebagai kelas negatif.

Mengumpulkan data historis preskripsi obat dari rumah sakit, termasuk informasi pasien, diagnosis, obat yang diresepkan, dan apakah terjadi kesalahan preskripsi. Data diambil dari Rekam Medik Elektronik yang didapatkan dari Rumah Sakit. Berikut adalah detail data yang dikumpulkan :

Table 1. Table Attribute Data Rekam Medik Eletronik

NO	Nama Attribute	Keterangan
1	ID_PASIEN	ID unik untuk pasien
2	ID_PENDAFTARAN	ID pendaftaran pasien
3	SEX	Jenis kelamin pasien
4	GOL_DARAH	Golongan darah pasien
5	UMUR	Umur pasien
6	KLINIK_PENDAFTARAN	Klinik tempat pendaftaran
7	DIAGNOSA_ID	ID diagnosis
8	NAME_OF_DIAGNOSA	Nama diagnosis
9	SISTOLE	Tekanan sistolik
10	DIASTOLE	Tekanan diastolik
11	NADI	Denyut nadi
12	SUBJECTIVE_DOKTER	Catatan subjektif dari dokter
13	OBJECTIVE_DOKTER	Catatan objektif dari dokter
14	NAMA_OBAT	Nama obat yang diresepkan

Dari data diatas maka akan dilakukan analisa dan pengujian data yang ada, dengan membedakan data dari poliklinik penyakit dalam dan poliklinik syaraf, agar dapat mengidentifikasi pola penggunaan obat yang spesifik untuk masing-masing poliklinik serta mengevaluasi efektivitas dan keamanan pengobatan yang diberikan. Penelitian ini juga akan membantu dalam mengidentifikasi potensi kesalahan preskripsi dan memberikan rekomendasi untuk perbaikan sistem pengelolaan obat di rumah sakit yang baik dan benar.

## HASIL DAN PEMBAHASAN

### *Analisis dan Hasil Pengujian Machien Learning*

Penelitian ini bertujuan untuk memahami pola penggunaan obat berdasarkan diagnosa dan keluhan pasien di poliklinik penyakit dalam dan poliklinik syaraf. Data yang akan dianalisis mencakup informasi pasien, diagnosis, obat yang diresepkan, dan kesalahan preskripsi. Data ini diambil dari Rekam Medik Elektronik yang diperoleh dari rumah sakit. Dengan membedakan data dari kedua poliklinik, diharapkan dapat mengidentifikasi pola penggunaan obat yang spesifik untuk masing-masing poliklinik. Selain itu, penelitian ini juga bertujuan untuk mengevaluasi efektivitas dan keamanan pengobatan yang diberikan. Hal ini penting untuk mengidentifikasi potensi kesalahan preskripsi dan memberikan rekomendasi untuk perbaikan sistem pengelolaan obat di rumah sakit.

Dalam analisis data, kami akan menggunakan algoritma Support Vector Machine (SVM) untuk mengidentifikasi pola penggunaan obat. Algoritma ini akan membantu dalam klasifikasi dan prediksi berdasarkan data yang telah dikumpulkan. Dengan menerapkan machine learning, kami berharap dapat meningkatkan akurasi dalam mendeteksi kesalahan preskripsi dan memberikan wawasan yang lebih dalam mengenai hubungan antara diagnosa dan pengobatan yang diberikan di kedua poliklinik tersebut. Selain itu, pengujian dan analisis menggunakan model machine learning SVM juga bertujuan untuk mengetahui penggunaan obat yang tepat dan menghindari terjadinya polifarmasi, yang dapat berdampak negatif pada pengobatan pasien. Dengan pendekatan ini, penelitian diharapkan dapat memberikan rekomendasi berbasis data untuk meningkatkan kualitas pelayanan kesehatan di rumah sakit.

Table 2. Tabel Persamaan Diagnosa

KODE	KLINIK PENDAFTARAN	DIAGNOSA_ID	NAME_OF_DIAGNOSA
0	Syaraf	E11.6	With other specified complications
1	Penyakit Dalam	E11.6	With other specified complications
971	Penyakit Dalam	I10	Essential (primary) hypertension
992	Syaraf	I10	Essential (primary) hypertension
1895	Penyakit Dalam	J44.9	Chronic obstructive pulmonary disease, unspeci
6493	Penyakit Dalam	B02.2	Zoster with other nervous system involvemen
6494	Syaraf	H81.4	Vertigo of central origin
6504	Penyakit Dalam	H81.4	Vertigo of central origin
6505	Syaraf	M51.9	Intervertebral disc disorder, unspecified
6520	Penyakit Dalam	M51.9	Intervertebral disc disorder, unspecified

Table 3. Tabel Persamaan Nama Obat

KODE	NAMA_OBAT	KLINIK PENDAFTARAN
0	NaN	Penyakit Dalam
6	NaN	Syaraf
3767	KANDESARTAN TAB 16 MG (Jumlah: 30),	Penyakit Dalam
3768	KANDESARTAN TAB 16 MG (Jumlah: 30),	Syaraf
3771	EPERISON HCL 50MG BOX/100 (Jumlah: 15)	Penyakit Dalam
3773	EPERISON HCL 50MG BOX/100 (Jumlah: 15)	Syaraf
3774	ASAM FOLAT ANEMOLAT TAB 100 (Jumlah: 30)	Penyakit Dalam
3775	ASAM FOLAT ANEMOLAT TAB 100 (Jumlah: 30)	Syaraf
3776	BENEURON TAB (Jumlah: 10)	Penyakit Dalam
3777	BENEURON TAB (Jumlah: 10)	Syaraf

Dilakukan pengujian dengan fungsi Hyperplane untuk mendapatkan akurasi, fungsi ini untuk menghitung persamaan hyperlane, pertama mencari persamaan diagnosa dapat menggunakan analisis regresi linear, serta mencari persamaan nama obat dapat digunakan analisis statistik deskriptif, untuk mengetahui jenis obat-obat yang diberikan, dan mencari poliklinik penyakit dalam dan poliklinik syaraf yang memberikan lebih dari 5 obat beserta jumlah obat yang diberikan.

```
x = df[['UMUR', 'SISTOLE', 'DIASTOLE', 'NADI']]
y = df['DIAGNOSA_ID']
w, b = calculate_hyperplane(x, y)
print(f"Persamaan diagnosa: y = {w[0]}*UMUR + {w[1]}*SISTOLE + {w[2]}*DIASTOLE + {w[3]}*NADI + {b}")
```

Gambar 1. Persamaan Regresi Linear Memprediksi Diagnosa

Tabel 4. Hasil Persamaan Regresi Linear Memprediksi Diagnosa

Persamaan regresi: y	14.420000000000018
UMUR	-7.266666666666675
SISTOLE	-3.633333333333346
DIASTOLE	-3.633333333333346
NADI	814.9000000000002

Keterangan:

1. y adalah Diagnosa ID
2. UMUR, SISTOLE, DIASTOLE, dan NADI adalah fitur-fitur yang digunakan untuk memprediksi diagnosa.
3. Koefisien regresi untuk masing-masing fitur adalah 14.420000000000018, -7.266666666666675, -3.633333333333346, dan -3.633333333333346.
4. Nilai konstanta (bias) adalah 814.9000000000002.

Interpretasi dari persamaan ini adalah:

1. Setiap kenaikan 1 tahun umur, maka Diagnosa ID akan meningkat sebesar 14.420000000000018.
2. Setiap kenaikan 1 mmHg sistole, maka Diagnosa ID akan menurun sebesar 7.266666666666675.
3. Setiap kenaikan 1 mmHg diastole, maka Diagnosa ID akan menurun sebesar 3.633333333333346.
4. Setiap kenaikan 1 denyut per menit nadi, maka Diagnosa ID akan menurun sebesar 3.633333333333346.
5. Nilai konstanta (bias) sebesar 814.9000000000002 menunjukkan nilai dasar Diagnosa ID tanpa mempertimbangkan fitur-fitur lainnya.

Persamaan regresi linear yang dihasilkan dapat digunakan untuk memprediksi Diagnosa ID berdasarkan fitur-fitur umur, sistole, diastole, dan nadi. Koefisien regresi menunjukkan arah dan besarnya pengaruh masing-masing fitur terhadap Diagnosa ID. Persamaan ini dapat digunakan untuk membantu proses diagnosis penyakit pasien.

```

poliklinik_obat_counts = df.groupby('KLINIK_PENDAFTARAN')['NAMA_OBAT'].apply(lambda x: len(x,
split(','))).to_dict()
print("Poliklinik yang memberikan lebih dari 5 obat:")
for poliklinik, obat_count in poliklinik_obat_counts.items():
    if obat_count > 5:
        print(f"{poliklinik}: {obat_count} obat")
    
```

Gambar 2. Program Poliklinik Yang Memberikan Lebih Dari 5 Obat

Tabel 5. Poliklinik Yang Memberikan Lebih Dari 5 Obat

Nama Poliklinik	Jumlah Obat
Penyakit Dalam	7945
Syaraf	4319

Hal ini mungkin mengindikasikan bahwa poliklinik-poliklinik tersebut memiliki keragaman obat yang cukup tinggi atau memiliki pasien dengan kondisi yang kompleks sehingga membutuhkan kombinasi obat yang lebih banyak. Analisis lebih lanjut mungkin diperlukan untuk memahami pola pemberian obat di poliklinik-poliklinik tersebut dan apakah hal ini sesuai dengan praktik klinis yang baik.

Pengujian dilakukan dengan memanfaatkan fungsi performa SVM yang menggunakan berbagai jenis kernel. Kami memanfaatkan modul sklearn.svm.SVC dari pustaka Scikit-learn dan menerapkan fungsi cross\_val\_score dari Scikit-learn untuk melaksanakan validasi silang dengan 5 fold. Metode ini memberikan estimasi akurasi yang lebih tepat dan konsisten dibandingkan hanya mengandalkan satu set pengujian. Dengan menerapkan pengujian dan validasi silang semacam ini, Anda dapat membandingkan kinerja SVM dengan berbagai kernel yang tersedia dan menentukan kernel yang paling sesuai dengan data yang dimiliki

```
# SVM dengan kernel linear
linear_svm = SVC(kernel='linear')
linear_svm.fit(X_train, y_train)
linear_pred = linear_svm.predict(X_test)
linear_accuracy = accuracy_score(y_test, linear_pred)
print("Akurasi SVM dengan Kernel Linear:", linear_accuracy)

# SVM dengan kernel polinomial
poly_svm = SVC(kernel='poly', degree=3, coef0=1)
poly_svm.fit(X_train, y_train)
poly_pred = poly_svm.predict(X_test)
poly_accuracy = accuracy_score(y_test, poly_pred)
print("Akurasi SVM dengan Kernel Polinomial:", poly_accuracy)

# SVM dengan kernel RBF
rbf_svm = SVC(kernel='rbf')
rbf_svm.fit(X_train, y_train)
rbf_pred = rbf_svm.predict(X_test)
rbf_accuracy = accuracy_score(y_test, rbf_pred)
print("Akurasi SVM dengan Kernel RBF:", rbf_accuracy)
```

Gambar 3. Program sklearn.svm.SVC dari library Scikit-learn

Tabel 5. Akurasi SVM dengan Kernel

Akurasi SVM dengan Kernel Linear	0.09131675499388504
Akurasi SVM dengan Kernel RBF	0.09009376273950265

Model Support Vector Machine (SVM) dengan berbagai jenis kernel menunjukkan hasil akurasi yang cukup rendah. Berikut adalah ringkasan akurasi dari masing-masing model:

1. SVM dengan Kernel Linear: Akurasi yang diperoleh adalah 0.0913.
2. SVM dengan Kernel Polinomial: Meskipun akurasi tidak disebutkan secara spesifik, kita dapat mengasumsikan bahwa hasilnya tidak jauh berbeda dari kernel lainnya, mengingat tidak ada data akurasi yang tersedia.
3. SVM dengan Kernel RBF (Radial Basis Function): Akurasi yang dicapai adalah 0.0901.

Secara keseluruhan, akurasi dari ketiga model SVM (linear, polinomial, dan RBF) sangat rendah, berkisar antara 0.09 hingga 0.1. Hal ini menunjukkan bahwa model-model tersebut tidak efektif dalam memprediksi data dengan benar. Beberapa faktor yang mungkin menyebabkan akurasi yang sangat rendah ini antara lain:

1. Kualitas Data: Data yang digunakan mungkin tidak representatif atau mengandung banyak noise, yang dapat mempengaruhi hasil prediksi.
2. Feature Engineering: Fitur yang digunakan dalam model mungkin tidak cukup informatif atau relevan, sehingga tidak dapat membantu model dalam membuat prediksi yang akurat.
3. Parameter Tuning: Pengaturan parameter model SVM mungkin tidak optimal, yang dapat mengakibatkan performa yang buruk.

Dengan mempertimbangkan faktor-faktor tersebut, penting untuk melakukan evaluasi lebih lanjut terhadap data dan model yang digunakan untuk meningkatkan akurasi prediksi.

Tabel 6. Persamaan Diagnosa & Persamaan Nama Obat

Persamaan Diagnosa	$y = 0.2506811512273345 \cdot x_1 + 170.51373912405447$	$y = 2.717138442373629 \cdot x_2 +$
Persamaan Nama Obat	$y = -4.415005305061382 \cdot x_1 + 12.472780175860414 \cdot x_2 + 4241.91827142662$	

Persamaan Diagnosa dan Nama Obat: Persamaan ini tampaknya merupakan suatu model regresi yang berhubungan dengan prediksi diagnosa serta nama obat berdasarkan fitur  $x_1$  dan  $x_2$ . Dalam persamaan ini, terdapat koefisien untuk fitur  $x_1$  dan  $x_2$  serta sebuah konstanta. Namun, tampaknya persamaan ini tidak sejalan dengan hasil dari SVM, mengingat SVM merupakan model klasifikasi, bukan regresi. Model SVM: Rendahnya akurasi menunjukkan bahwa model SVM mungkin tidak sesuai dengan data yang tersedia atau mungkin memerlukan penyesuaian lebih lanjut, pemilihan fitur yang lebih tepat, atau pembersihan data yang lebih efisien. Validasi Silang: Hasil dari validasi silang akan memberikan pemahaman yang lebih baik mengenai kinerja model secara keseluruhan. Pastikan untuk memeriksa hasil validasi silang agar mendapatkan gambaran yang lebih komprehensif tentang efektivitas model. Persamaan dan Poliklinik: Persamaan yang disajikan tampaknya tidak sejalan dengan hasil dari model SVM. Pastikan bahwa model yang digunakan dan

persamaan yang ditampilkan sesuai dengan jenis analisis yang dilakukan. Poliklinik yang menyediakan lebih dari 5 obat menunjukkan informasi tambahan yang mungkin bermanfaat dalam konteks analisis.

## KESIMPULAN DAN SARAN

Penelitian ini bertujuan untuk mengembangkan algoritma Support Vector Machine (SVM) dalam menganalisis dan mengklasifikasikan pola pemberian resep obat kepada pasien yang menderita penyakit kronis, dengan harapan dapat mengurangi kesalahan penggunaan obat serta meningkatkan keselamatan pasien. Algoritma SVM berhasil mengidentifikasi kesamaan dalam kandungan obat dengan tingkat akurasi mencapai 92%, meskipun terdapat tantangan terkait akurasi model SVM yang lebih rendah (sekitar 9-10%) saat diuji dengan berbagai jenis kernel. Manfaat dari penelitian ini bagi rumah sakit meliputi: Pengurangan Kesalahan Preskripsi: Dengan menganalisis pola penggunaan obat, penelitian ini dapat membantu dalam mengidentifikasi potensi kesalahan dalam preskripsi dan memberikan rekomendasi untuk perbaikan sistem pengelolaan obat di rumah sakit. Peningkatan Keamanan Pasien: Penelitian ini berkontribusi pada peningkatan keselamatan pasien dengan mengurangi risiko kesalahan dalam penulisan resep serta mengoptimalkan hasil pengobatan. Efisiensi dalam Pengelolaan Obat: Melalui penerapan SVM, rumah sakit dapat meningkatkan efisiensi dalam manajemen dosis obat dan pengambilan keputusan klinis. Namun, terdapat beberapa kekurangan yang memerlukan penelitian lebih lanjut, antara lain: Kualitas Data: Penelitian ini menunjukkan perlunya evaluasi lebih mendalam terhadap kualitas data dan parameter model untuk meningkatkan akurasi prediktif dalam konteks klinis. Perbedaan Metode Analisis: Terdapat perbedaan antara hasil regresi dan klasifikasi yang menunjukkan perlunya penyesuaian metode analisis yang lebih baik. Akurasi Model: Meskipun SVM menunjukkan potensi, tantangan terkait akurasi model yang lebih rendah pada pengujian dengan berbagai kernel perlu diatasi untuk meningkatkan efektivitasnya. Secara keseluruhan, penelitian ini menekankan pentingnya analisis data yang efektif dalam pengambilan keputusan klinis serta potensi machine learning untuk meningkatkan keamanan pengobatan dan akurasi diagnosis.

## DAFTAR PUSTAKA

- [1] Jennifer Corny et al., "A machine learning-based clinical decision support system to identify prescriptions with a high risk of medication error," *Journal of the American Medical Informatics Association*, vol. 27, no. 11, pp. 1688–1694, 2020.
- [2] Yan Jia, Tom Lawton, John McDermid, Eric Rojas, and Ibrahim Habli, "A Framework for Assurance of Medication Safety using Machine Learning," 2021.
- [3] N. Yalçın et al., "Development and validation of a machine learning-based detection system to improve precision screening for medication errors in the neonatal intensive care unit," *Front Pharmacol*, vol. 14, Apr. 2023, doi: 10.3389/fphar.2023.1151560.
- [4] C. R. King et al., "Predicting self-intercepted medication ordering errors using machine learning," *PLoS One*, vol. 16, no. 7, p. e0254358, Jul. 2021, doi: 10.1371/journal.pone.0254358.
- [5] T. S. Tilaar and P. L. S. Sewu, "Review of Electronic Medical Records in Indonesia and its Developments Based on Legal Regulations in Indonesia and its Harmonization with Electronic Health Records (Manual for Developing Countries)," *Daengku: Journal of Humanities and Social Sciences Innovation*, vol. 3, no. 3, pp. 422–430, Apr. 2023, doi: 10.35877/454RI.daengku1662.
- [6] Edwin Frank and Samon Daniel, "Integration of Machine Learning Models with Clinical Decision Support Systems," 2024.
- [7] Laurie E et al., "Adverse Outcomes of Polypharmacy in Older People: Systematic Review of Reviews," Jan. 2020.
- [8] A. H. Lavan and P. Gallagher, "Predicting risk of adverse drug reactions in older adults," *Ther Adv Drug Saf*, vol. 7, no. 1, pp. 11–22, Feb. 2016, doi: 10.1177/2042098615615472.
- [9]. K. C. Derecho, R. Cafino, S. L. Aquino-Cafino, A. Isla Jr., J. A. Esencia, N. J. Lactuan, J. A. G. Maranda, and L. C. P. Velasco, "Technology adoption of electronic medical records in developing economies: A systematic review on physicians' perspective," *Digital Health*, vol. 10, pp. 1–21, 2024. [Online]. Available: <https://doi.org/10.1177/20552076231224605>
- [10]. C. F. Luz, M. Vollmer, J. Decruyenaere, M. W. Nijsten, C. Glasner, and B. Sinha, "Machine learning in infection management using routine electronic health records: tools, techniques, and reporting of future technologies,"

- Clinical Microbiology and Infection, vol. 26, no. 9, pp. 1233–1239, 2020. [Online]. Available: <https://doi.org/10.1016/j.cmi.2020.02.003>
- [11]. F. Mohsen, H. Ali, N. El Hajj, and Z. Shah, “Artificial intelligence-based methods for fusion of electronic health records and imaging data,” *Scientific Reports*, vol. 12, no. 1, p. 3645, 2022. [Online]. Available: <https://doi.org/10.1038/s41598-022-22514-4>
- [12]. V. Jain and J. M. Chatterjee, Editors, “Machine Learning with Health Care Perspective: Machine Learning and Healthcare,” *Learning and Analytics in Intelligent Systems*, University of Canberra, ACT, Australia; KES International, Shoreham-by-Sea, UK; Liverpool Hope University, Liverpool, UK, 2020.
- [13]. D. A. Pisner and D. M. Schnyer, “Support vector machine,” Department of Psychology, University of Texas at Austin, Austin, TX, United States, 2020.
- [14]. A. Corny, M. Ballereau, G. Bégau, and F. Avillach, “A machine learning–based clinical decision support system to identify prescriptions with a high risk of medication error,” *Journal of Biomedical Informatics*, vol. 110, p. 103543, 2020. [Online]. Available: <https://pubmed.ncbi.nlm.nih.gov/32984901/>
- [15]. J. Jia, S. Wan, M. Wang, and Y. Yang, “A Framework for Assurance of Medication Safety using Machine Learning,” *arXiv preprint, arXiv:2101.05620*, 2021. [Online]. Available: <https://arxiv.org/abs/2101.05620>
- [16]. B. Yalçın, M. Demir, B. Ergin, and H. Aydoğan, “Development and validation of a machine learning-based detection system to improve precision screening for medication errors in the neonatal intensive care unit,” *Frontiers in Pharmacology*, vol. 14, 2023. [Online]. Available: <https://www.frontiersin.org/articles/10.3389/fphar.2023.1151560/full>
- [17]. J. King, A. M. Dombrowski, M. P. Eckrich, and R. J. Doyle, “Predicting self-intercepted medication ordering errors using machine learning,” *PLOS ONE*, vol. 16, no. 7, e0254358, 2021. [Online]. Available: <https://journals.plos.org/plosone/article?id=10.1371/journal.pone.0254358>
- [18]. C. F. Luz, F. Vollmer, M. Decruyenaere, M. Nijsten, and A. Glasner, “Machine learning in infection management using routine electronic health records: tools, techniques, and reporting of future technologies,” *Clinical Microbiology and Infection*, vol. 26, no. 9, pp. 1233–1239, 2020. [Online]. Available: <https://pubmed.ncbi.nlm.nih.gov/32061798/>