

OPTIMASI KINERJA ANALISIS KERNEL *SUPPORT VECTOR MACHINE* (SVM) UNTUK KLASIFIKASI OPERASI CAESAR PERSALINAN

Abdul Aziz Firdaus, Egi Pratama, Nurul Najwa Sabilla, Rahayu Laras Kinasih, Wiyanto

Teknik Informatika, Universitas Pelita Bangsa

Jalan Inspeksi Kalimalang, Tegal Danas, No. 009, Kabupaten Bekasi, Indonesia

abdul.aziz03@mhs.pelitabangsa.ac.id

ABSTRAK

Angka persalinan dengan tindakan *Sectio Caesarea* (SC) di Indonesia terus meningkat dan melebihi batas ideal yang ditetapkan oleh WHO yaitu 10–15%, dengan prevalensi mencapai 17,6%. Hal ini menimbulkan kekhawatiran karena prosedur SC memiliki risiko komplikasi yang lebih tinggi dibandingkan persalinan normal, termasuk infeksi, pendarahan, hingga kematian ibu dan bayi. Meskipun SC menjadi alternatif penting dalam kondisi tertentu, pemilihan metode persalinan yang tidak tepat dapat berdampak negatif terhadap keselamatan ibu dan anak. Keputusan medis yang selama ini cenderung subjektif membutuhkan pendekatan yang lebih objektif dan berbasis data. Penelitian ini bertujuan untuk mendapatkan optimasi kinerja dengan *Support Vector Machine* (SVM) terhadap kernel serta memperoleh performa model yang baik. Pemantauan perbandingan untuk membuat berbagai kernel SVM yang lebih baik akurasi untuk analisis SC. Hasil dari penelitian ini menghasilkan tingkat akurasi pada pengujian 83.36% menggunakan bantuan kernel RBF sebagai akurasi terbaik, dibandingkan dengan kernel *linear* sebesar 78.92%, kernel *sigmoid* sebesar 65.05%, kernel *polynomial* sebesar 82.39%. Selanjutnya, perhitungan ROC-AUC digunakan agar menghasilkan perhitungan yang rinci kepada keempat kernel, yaitu kernel *linear* 88.01%, kernel *polynomial* sebesar 89.28%, pada kernel *sigmoid* sebesar 70.19%. Kemudian, nilai grafik ROC-AUC untuk kernel RBF sebesar 89.86%, mengindikasikan bahwa model klasifikasi yang dibangun telah bekerja dengan baik serta memiliki potensi untuk dikembangkan pada penelitian lanjutan.

Kata kunci : *Caesar*, *Machine Learning*, SVM, Klasifikasi, KDD

1. PENDAHULUAN

Persalinan merupakan serangkaian proses keluarnya janin, plasenta, dan selaput dari rahim menuju jalan lahir. Proses ini dimulai dengan terbukanya dan melebarnya serviks akibat kontraksi rahim yang terjadi dengan ritme, lama, dan intensitas yang teratur. Awalnya kontraksi terjadi dengan kekuatan kecil, lalu berangsur meningkat hingga mencapai puncaknya saat pembukaan serviks sempurna, sehingga memungkinkan janin keluar dari rahim ibu [1]. Terdapat dua jenis proses persalinan [2] yaitu secara normal pervaginam dan melakukan operasi *Sectio Caesarea* (SC). SC adalah tindakan bedah untuk mengeluarkan janin dengan membuka dinding perut dan dinding rahim [3].

Angka aktivitas *Sectio Caesarea* (SC) di Indonesia menurut data dari Kemenkes RI menyatakan 927.000 dari 4.039.000 persalinan, yang dimana berdasarkan hasil survey total angka persalinan *caesar* sebesar 17,02%. Tindakan operasi *caesar* di Indonesia sudah melebihi batas yang telah ditetapkan oleh *World Health Organization* (WHO). Karena menurut penelitian terbaru WHO, telah menetapkan bahwa indikator persalinan secara *caesar* di setiap negara adalah antara 10-15%, sedangkan di Indonesia sebesar 17,6%, dengan prevalensi tertinggi di DKI Jakarta (31,3%) dan terendah di Papua (6,7%) [4]. Penggunaan metode persalinan *caesar* terus meningkat secara global, yang saat ini terhitung 21%. Jumlah ini akan terus meningkat sampai 2030 [5].

Berdasarkan data dari *World Health Organization* (WHO), apabila tingkat angka indikator

melebihi batas standar yang telah ditetapkan, hal ini mudah mempertinggi risiko kematian dan kecacatan pada ibu dan anak. Fakta bahwa persalinan secara *Sectio Caesarea* (SC) dapat berisiko menyebabkan angka kematian dan kecacatan dari pada persalinan normal, serta durasi perawatan yang lebih lama setelah operasi menimbulkan rasa kekhawatiran terkait persalinan secara *caesar* [6]. Jika dibandingkan dengan persalinan normal pervaginam, risiko kematian ibu terkait persalinan secara *Sectio Caesarea* dua kali lebih tinggi. Angka kematian ibu yang disebabkan oleh operasi *caesar* adalah satu per 1.000 kelahiran. Infeksi luka operasi, infeksi rahim, infeksi kandung kemih, dan infeksi usus menyumbang sekitar 90% kematian pada *caesar* [7].

Disisi lain persalinan dengan tindakan *Sectio Caesarea* (SC) merupakan menjadi preferensi dalam membantu persalinan bagi ibu yang tidak mampu melakukan persalinan secara normal ataupun memang bagi ibu yang ingin melakukan proses persalinan secara *caesar*. Hal ini dilakukan sebab alasan medis, permintaan pasien sendiri, atau alasan dari dokter [8].

Peluang seorang ibu dalam memilih proses persalinan berbeda-beda sesuai dengan kondisi kesehatan yang dimiliki. Pemilihan proses persalinan juga sangat penting sekali untuk dianalisis tentang pengurangan risiko kematian serta bahaya komplikasi pada ibu dan anak. Risiko jangka panjang dari proses persalinan secara *caesar* bagi ibu yaitu dinding rahim terhalang dengan tumbuhnya plasenta dalam rahim. Kondisi ini biasa disebut plasenta *prevetia*. Selain itu, bisa juga mengalami gangguan seperti plasenta akreta

yang dimana menyebabkan pendarahan hebat setelah melahirkan. Maka, sebab itulah harus dipertimbangkan dan diputuskan dengan tepat apakah ibu hamil lebih baik melakukan persalinan secara normal atau diperlukan proses melahirkan secara *caesar* [9]. Dalam hal ini, penentuan keputusan persalinan harus tepat agar tidak merugikan bagi ibu yang akan melahirkan. Karena selama proses kehamilan, banyak hal yang perlu dipersiapkan untuk menghadapi dampak langsung yang terjadi pada ibu dan bayi. Hal ini menjadi ketakutan seorang ibu yang akan melakukan proses persalinan seperti akan terjadinya keguguran, bayi dengan kondisi tidak sempurna atau cacat, hingga kematian, dan terutama depresi pasca melahirkan yang berdampak pada fisik maupun mental ibu.

Ini memberi ruang lingkup untuk mengembangkan model pengambilan keputusan untuk memilih mode persalinan yang tepat. Bidang ilmu *data mining* muncul sebagai solusi untuk permasalahan ekstraksi informasi dari *database* berukuran besar, dengan mengintegrasikan berbagai teknik yang mencakup statistik, *machine learning*, visualisasi data, *pattern recognition*, dan sistem basis data. Teknik *data mining* merupakan pendekatan yang mengkombinasikan metode analisis data dengan identifikasi pola bermakna dalam set data. Implementasi teknologi *data mining* diharapkan dapat meningkatkan efisiensi dalam proses pengambilan keputusan, sehingga memberikan manfaat bagi tenaga medis dalam menentukan diagnosis dan prognosis di lingkungan institusi kesehatan [10].

Dalam penelitian ini akan menjadi krusial karena kemampuan algoritma untuk menganalisis pola kompleks dalam data medis. Metode tradisional dalam menentukan kebutuhan operasi *caesar* sering kali bergantung pada evaluasi subjektif tenaga medis, yang dapat menyebabkan variasi dalam pengambilan keputusan. Dengan menerapkan *data mining* diharapkan dapat mengurangi variabilitas dalam pengambilan keputusan dengan menyediakan analisis berbasis data yang konsisten serta meningkatkan efisiensi dalam layanan kesehatan. Model yang dibuat dalam penelitian ini diharapkan memiliki performa lebih baik dalam mendeteksi faktor risiko dan mengurangi tingkat kesalahan dalam diagnosis. Hal ini tidak hanya membantu tenaga medis dalam membuat keputusan berbasis data, tetapi juga berpotensi menurunkan jumlah prosedur yang tidak perlu, mengurangi risiko komplikasi, serta meningkatkan keselamatan ibu dan bayi.

Penelitian ini mengaplikasikan *Support Vector Machine* (SVM) sebagai teknik analisis utama untuk memproses data yang dikumpulkan guna mengklasifikasikan kebutuhan prosedur *caesar* pada proses persalinan. Tujuannya adalah menghasilkan klasifikasi yang akurat berdasarkan berbagai kondisi ibu hamil, untuk menentukan apakah persalinan *caesar* diperlukan atau tidak. Dengan demikian, analisis ini dapat membantu prediksi keselamatan ibu

dan bayi dengan mempertimbangkan berbagai parameter yang terdapat dalam algoritma SVM yang dianalisis serta disesuaikan dengan *dataset* penelitian.

2. TINJAUAN PUSTAKA

2.1. Penelitian Terdahulu

Penggunaan model *Support Vector Machine* (SVM) telah banyak diadaptasi untuk membangun pelatihan serupa dalam prediksi proses persalinan hal ini sejalan dengan studi komparatif oleh Vizhiyarsi S, Matheswari S, Meaga J, dan Nishani S dengan judul “*Predicting Childbirth Modes: A Comparative Analysis of Machine Learning Algorithm*” pada tahun 2025. Terdapat potensi besar dalam memanfaatkan metode komputasi canggih pada data kebidanan untuk mendukung pengambilan keputusan di ruang persalinan. Studi ini mengeksplorasi efektivitas berbagai algoritma pembelajaran mesin dan membandingkan kemampuan prediktifnya dalam memprediksi persalinan. *Decision Tree* (DT) menunjukkan akurasi 57% dengan skor metrik sekitar 60%, *Support Vector Machine* (SVM) memiliki akurasi 64%, *K-Nearest Neighbors* (KNN) mencatat akurasi 65%, *Random Forest* (RF) unggul dengan akurasi 83% dan metrik hingga 80%, menunjukkan performa terbaik dengan pendekatan ansambel. SVM menjadi posisi terendah dalam penelitian ini, namun tetap menunjukkan kinerja yang stabil dengan presisi, recall, dan skor F1 di kisaran 68–70%, serta memiliki potensi untuk ditingkatkan melalui pemilihan kernel dan parameter pada algoritma SVM yang tepat akan dilakukan pada penelitian saat ini [11].

Selanjutnya, dalam penelitian menurut studi Abdul Azis Abdillah, Azwardi, Sulaksana Permana, Iwan Susanto, Fuad Zainuri, dan Samsul Arifin dalam penelitian berjudul “*Performance Evaluation Of Linear Discriminant Analysis And Support Vector Machines To Classify Cesarean Section*” pada tahun 2021. Mengatakan bahwa tingginya kerentanan rumah sakit terhadap Covid-19 membuat persalinan di fasilitas kesehatan ini menjadi aktivitas berisiko tinggi. Selain itu, rumah sakit saat ini hanya menerima persalinan *caesar*, sedangkan ibu yang bisa melahirkan secara vaginal dianjurkan untuk melahirkan di bidan karena kemungkinan terpapar Covid-19 jauh lebih rendah. Tujuan penelitian ini adalah untuk mengevaluasi efektivitas metode LDA-SVM dalam memprediksi metode persalinan yang dibutuhkan oleh calon ibu, baik melalui prosedur bedah *caesar* maupun persalinan normal. LDA itu sendiri merupakan salah satu proses reduksi dimensi data dalam hal persiapan sebelum melakukan *modelling*. Pada kasus ini LDA-SVM mampu mengklasifikasikan metode operasi *caesar* dengan baik dengan akurasi hingga 100% [12].

Dalam penelitian lain SVM diuji dengan data kesehatan selain untuk persalinan *caesar* oleh Rohmatullah Sony Wijaya, Arie Qur'ania, dan Irma Anggraeni berjudul “*Klasifikasi Penyakit Cacar Monyet Menggunakan Support Vector Machine*

(SVM)” pada tahun 2024. Pada Juli 2022, cacar monyet menjadi wabah di beberapa negara non-endemik. Untuk mencegah dan menangani penyakit ini, diperlukan identifikasi dini menggunakan metode klasifikasi. Penelitian ini dengan algoritma SVM dengan empat kernel: *linear*, RBF, *sigmoid*, dan *polynomial*. SVM dipilih karena kemampuannya mengenali pola tidak *linear* melalui berbagai kernel. Hasil terbaik diperoleh dari kernel *polynomial* dengan akurasi 75% sehingga nilai ROC AUC sebesar 0,81. Kernel lainnya memiliki akurasi seperti kernel *linear* sebesar 70,5%, kernel RBF sebesar 66%, dan kernel *sigmoid* sebesar 45% [13].

2.2. Evaluasi Kinerja

Kinerja klasifikasi dievaluasi menggunakan *confusion matrix* dan kurva ROC-AUC, yang memberikan gambaran jelas tentang performa model dengan membandingkan hasil prediksi terhadap label sebenarnya. *Confusion matrix* ini terdiri umumnya memiliki empat kategori yaitu *true positive* (TP), *true negative* (TN), *false positive* (FP), dan *false negative* (FN). Dari kategori ini, dapat mengetahui berbagai matriks evaluasi yang penting untuk menilai efektivitas model [14].

Rumus Akurasi mengukur proporsi prediksi yang benar dari total prediksi yang dibuat, dan dapat dihitung dengan persamaan (1).

$$Akurasi = \frac{TP+TN}{TP+TN+FP+FN} \quad (1)$$

Precision menunjukkan seberapa tepat prediksi positif yang dihasilkan oleh model, dihitung dengan persamaan (2).

$$Precision = \frac{TP}{TP+FP} \quad (2)$$

Recall mengukur kemampuan model dengan mendeteksi semua kasus positif yang ada melalui persamaan (3).

$$Recall = \frac{TP}{TP+FN} \quad (3)$$


F1-Score adalah metrik yang menggabungkan *precision* dan *recall* menjadi satu nilai tunggal, yang sangat berguna ketika perlu menyeimbangkan. Berikut persamaan (4) untuk *F1-Score*.

$$F1 = 2 \times \frac{Precision \times Recall}{Precision+Recall} \quad (4)$$

Untuk kurva *Receiver Operating Characteristic* (ROC) adalah grafik dua dimensi yang menunjukkan kinerja model klasifikasi, dengan *False Positive Rate* (FPR) di sumbu horizontal dan *True Positive Rate* (TPR) di sumbu vertikal. Sedangkan *Area Under Curve* (AUC) digunakan untuk menghitung area dibawah kurva ROC. Nilai AUC dapat dihitung dengan menambahkan area trapesium dari ukuran AUC. Nilai AUC berada diantara 0 dan 1 dan semakin mendekati angka 1 maka semakin baik model dalam mengklasifikasi data [15].

3. METODE PENELITIAN

Bagian ini menjelaskan langkah-langkah dalam proses *data mining*. Pada penelitian ini, algoritma *Support Vector Machine* (SVM) digunakan untuk mengklasifikasikan data bertipe numerik. Proses tersebut didukung oleh pendekatan *Knowledge Discovery in Databases* (KDD), yang mencakup serangkaian tahapan pengolahan data dan dikombinasikan dengan kerangka penelitian pada Gambar 1, sehingga menghasilkan informasi yang berguna. [16].



Gambar 1. Kerangka Penelitian

3.1. Data Selection

Tahapan awal dalam proses KDD adalah seleksi data, di mana peneliti memilih atribut-atribut yang relevan. Pada penelitian ini, data yang digunakan berasal dari *Sectio Caesarea* (SC) dengan total 34 atribut awal.

3.2. Data Preprocessing

Proses menyediakan data untuk analisis dengan menghapus atau mengubah data yang salah, tidak relevan, dan tidak bermanfaat yang dapat menyebabkan saat proses ini tidak dilakukan seperti terdapat data yang tidak konsisten, serta dapat menurunkan performa model. Penelitian pada data *caesar* ini tidak memanfaatkan atribut tanggal dan id, sebab tidak relevan.

3.3. Data Transformation

Pada studi kasus ini, jumlah atribut yang cukup banyak dalam *dataset* dibutuhkan untuk dilakukannya proses transformasi data. Reduksi dimensi dilakukan menggunakan metode *Principal Component Analysis* (PCA) untuk menyederhanakan data dari dimensi tinggi ke dimensi yang lebih rendah.

3.4. Data Mining Dengan SVM

Tahap ini adalah tahap penting dalam penelitian ini, dimana peneliti akan mencari pengetahuan atau pola dalam data yang telah dikumpulkan menggunakan algoritma *Support Vector Machine* (SVM). SVM dapat membuat prediksi baik dalam klasifikasi. Pada dasarnya, SVM memiliki prinsip *linier*, tetapi saat ini SVM telah berkembang pesat dan kemudian dapat dimanfaatkan untuk menyelesaikan permasalahan *non-linier*. Selanjutnya, untuk menghadapi masalah yang tidak dapat diproses secara *linier*, SVM memasukkan sebuah kernel. Di bidang tanpa dimensi ini, peneliti akan mencari pemisah atau sering disebut *hyperplane*. *Hyperplane* yang ingin ditemukan SVM adalah yang dapat memaksimalkan margin antara dua kelas. Peneliti dapat menemukan *hyperplane* terbaik antara dua data dengan memperkirakan tepi dan kemudian menemukan titik maksimum dari pembatas. Konsep dasar SVM melibatkan pemilihan *hyperplane* yang paling optimal sebagai pembatas antar kelas [12].

3.4.1. Hyperparameter Kernel SVM

Fungsi kernel sebagai pemisah yang digunakan dalam penelitian seperti kernel *linear* dan kerner *non-linear*. Kernel *linear* digunakan untuk memisahkan data berdasarkan garis lurus (*hiperplane linear*). Kernel ini digunakan ketika data dapat dipisahkan secara *linear* di ruang fitur, persamaan (5) sebagai persamaan kernel *linear*.

$$K(x_j, x_k) = x_j x_k \quad (5)$$

Selain itu, kernel *non-linear* seperti *polynomial*, RBF, dan *sigmoid* biasanya digunakan untuk mengklasifikasikan data dengan data. *Degree* (d), koefisien (*coef*), C, dan *gamma* adalah parameter yang biasanya digunakan. Persamaan (6) dalam bentuk kernel *polynomial*.

$$K(x_j, x_k) = (x_j, x_k + 1)^d \quad (6)$$

Kernel *radial basis function* (RBF), juga dikenal sebagai kernel *gaussian*, menggunakan parameter *gamma* dan C. Karena kinerja pembelajarannya yang luar biasa, kernel *gaussian* lebih banyak digunakan. Persamaan (7) untuk kalkulasi kernel *gaussiana*.

$$K(x_i, x_j) = \exp\left(-\frac{\|x_i - x_j\|^2}{2\sigma^2}\right) \quad (7)$$

Kernel *sigmoid* adalah salah satu kernel yang dikembangkan dari JST atau jaringan saraf tiruan. Parameter yang umumnya digunakan kernel *sigmoid* yaitu *gamma* dan C yang persamaan (8) sebagai perhitungan [13].

$$K(x_j, x_k) = \tanh(\gamma \cdot x_j, x_k + r) \quad (8)$$

3.5. Interpretation dan Evaluation

Tahap *Interpretation* dan *evaluation* merupakan tahap interpretasi data dengan menggunakan *aplikasi data mining*. Pengujian data dan evaluasi hasil pengujian dalam penelitian ini menggunakan *Python*. Pada tahap *evaluation*, tahap di mana peneliti memprediksi ibu hamil yang akan *caesar* atau tidak *caesar* menggunakan *Support Vector Machine* (SVM). Lalu, performa dengan *confusion matrix* serta dilengkapi dengan kurva ROC-AUC pada *testing data*.

4. HASIL DAN PEMBAHASAN

4.1. Data Selection

Data yang digunakan dalam penelitian ini adalah data operasi *caesar* (CS) pada persalinan tahun 2016 yang diperoleh dari *website* *datadryad.org*, link: datadryad.org/dataset/doi:10.5061/dryad.g7t04#, dengan total 3602 data dengan 34 atribut dan dua kelas, yaitu *caesar* (1) sejumlah 1.801 wanita dan Bukan *caesar* (0) sejumlah 1.801 wanita. Berikut *dataset* bagian atribut penelitian dapat dilihat pada Tabel 1 [17]. Data ini akan dianalisis menggunakan *Google Colab*.

Tabel 1. Atribut, Deskripsi dan Value Dataset

Atribut	Deskripsi	Value
<i>Patient_ID</i>	Nomor ID	Nomor
<i>Indexdate</i>	Tanggal	Nomor
<i>Age</i>	Tahun Lahir	Nomor
<i>Duration till next pregnancy in days</i>	Hari berikutnya hingga kehamilan berikutnya	Nomor
<i>Obesity</i>	Berat	0 or 1
<i>Ruptured membranes</i>	Pecahnya membran prematur	0 or 1
<i>Placenta Disorders</i>	Suatu kompilasi kehamilan dimana plasenta terlepas sebagian atau sepenuhnya dari rahim sebelum kelahiran bayi	0 or 1
<i>Condition of the placenta</i>	-	0 or 1
<i>Premature Separation</i>	Kondisi di mana plasenta terpisah dari lapisan rahim	0 or 1
<i>Bleeding</i>	-	0 or 1
.....		
<i>Latex allergy status</i>	Reaksi sistem kekebalan terhadap protein dalam lateks karet alam, produk yang terbuat dari cairan pohon karet	0 or 1

4.2. Data Preprocessing

Tahap ini merupakan proses pembersihan data untuk memastikan pengukuran yang relevan terhadap target variabel (*y*) dalam penelitian ini, yaitu '*Caesarean section*'. Atribut data yang tidak relevan, seperti '*Patient_ID*' dan '*Indexdate*', dihapus sehingga jumlah atribut yang digunakan menjadi 32 atribut. Selain itu, data yang tidak memiliki nilai

(missing values) maupun data identik yang muncul lebih dari satu kali (*duplicate*) dihilangkan. Pada *dataset* ini, tidak ditemukan *missing values* maupun *duplicate*.

Dataset kemudian dipartisi dengan proporsi 80% sebagai *training data* dan 20% sebagai *testing data*, menghasilkan 2.881 sampel untuk proses pelatihan model dan 721 sampel untuk evaluasi performa.

4.3. Data Transformation

Data transformasi akan dikerjakan setelah proses seleksi serta pembersihan data berakhir. Dalam tahap ini, data dikombinasikan dan ditransformasikan menjadi format yang lebih optimal guna keperluan eksplorasi data atau aplikasi algoritma tertentu. Pada penelitian ini, transformasi dilakukan menggunakan kernel PCA untuk mereduksi dimensi data dari 32 menjadi 2. Adapun langkah yang sebelum implementasi kernel PCA dengan standarisasi data dengan 'Standard Scaler' secara matematis menggunakan persamaan (9) berikut.

$$Z = \frac{x - \bar{x}}{\sigma} \quad (9)$$

Perubahan skala data dapat dilihat pada Tabel 2, ini untuk standarisasi data pelatihan (*training*).

Tabel 2. Standarisasi Data Pelatihan (*Training*)

Age	Duration till next pregnancy in days		Latex allergy status
-0.53179607	-0.24835009		-0.12738033
-0.53179607	-1.21404278		-0.12738033
-0.3242782	2.26351599		-0.12738033
.....			
1.95841845	2.54044257		-0.12738033
0.50579331	-1.24777102		-0.12738033
0.50579331	-0.05308135		-0.12738033


Selanjutnya, untuk Tabel 3, merupakan standarisasi untuk data pengujian (*testing*).

Tabel 3. Standarisasi Data Pengujian (*Testing*)

Age	Duration till next pregnancy in days		Latex allergy status
-1.56938545	-1.06670364		-0.12738033
-2.19193908	0.54515107		-0.12738033
0.29827543	-0.75782399		-0.12738033
.....			
0.09075756	-1.04185125		-0.12738033
-0.53179607	0.8185273		-0.12738033
0.29827543	-0.35841066		-0.12738033

Maka, setelah melakukan standarisasi, dapat diimplementasikan kernel PCA dengan parameter '*n_components=2*', yang berarti data akan direduksi menjadi dua komponen utama. Nilai ini menunjukkan bahwa dari sekian banyak atribut awal, hanya dua

dimensi hasil transformasi yang dipertahankan karena dianggap paling merepresentasikan variasi data secara optimal.



Gambar 2. Visualisasi Hasil Kernel PCA

Gambar 2, merupakan hasil dari visualisasi berbentuk seperti tiga cabang dengan data yang bercampur diseluruh pola data. Penelitian menggunakan *Support Vector Machine* (SVM) dapat menangani pemisahan dua kelas dengan mencari *hyperplane* terbaik yang akan dijelaskan pada tahapan selanjutnya pada subbab 4.4.

4.4. Data Mining

Proses menemukan pola atau informasi yang menarik dalam kumpulan data dengan teknik tertentu. *Data mining* menggunakan berbagai teknik, metode, atau algoritma tergantung pada tujuan proses dan jenis data yang diproses. Saat ini, penelitian dilakukan menggunakan algoritma *Support Vector Machine* (SVM).

Jenis kernel yang sudah ada di SVM dengan parameter tertentu untuk menghasilkan berbagai kinerja model. Adapun parameter untuk setiap kernel, pertama untuk kernel RBF menggunakan parameter $C = 1.0$ dan $\text{Gamma} = 2$, untuk kernel *sigmoid* adalah $C = 1.0$, $\text{Gamma} = 2$ dan $\text{Coef} = 0.0$, kernel *polynomial* penggunaan parameter $\text{Gamma} = 2$, $\text{Degree} = 3$, dan $\text{Coef} = 0.0$, dan kernel *linear* dengan parameter $C = 1.0$. Kode program menggunakan *library sklearn* sebagai berikut.

4.5. Pelatihan Model SVM

```
Def plot_train_data (kernel):
    # Train SVM model
    clf = SVC(kernel=kernel,
              gamma=2).fit(X_train_kpca,
                          y_train)
```

4.6. Membuat plot kernel PCA

```
# Create plot
fig, ax = plt.subplots(figsize=(6, 5))
x_min, x_max = X_train_kpca[:, 0].min() - 1,
X_train_kpca[:, 0].max() + 1
y_min, y_max = X_train_kpca[:, 1].min() - 1,
X_train_kpca[:, 1].max() + 1
ax.set_xlim(x_min, x_max)
ax.set_ylim(y_min, y_max)
```

4.7. Membuat plot decision boundary

```
# Plot decision boundary
DecisionBoundaryDisplay.from_estimator(
    clf, X_train_kpca, ax=ax,
    response_method="predict",
    plot_method="pcolormesh", alpha=0.3)
DecisionBoundaryDisplay.from_estimator(
    clf, X_train_kpca, ax=ax,
    response_method="decision_function",
    plot_method="contour",
    levels=[-1, 0, 1], colors=["k", "k", "k"],
    linestyle=["--", "-", "-.-"])
```

4.8. Membuat plot training data

```
# Plot training data
scatter = ax.scatter(X_train_kpca[:, 0],
X_train_kpca[:, 1], c=y_train, s=30,
edgecolors="k")
ax.legend(*scatter.legend_elements(),
loc="upper right", title="Classes")
ax.set_title(f'Decision Boundary of SVM
({kernel} Kernel)')
```

Kode tersebut digunakan melatih SVM dengan kernel yang sudah ditentukan dan menampilkan atas keputusan dari hasil reduksi dimensi. Plot yang dihasilkan menunjukkan bagaimana model memisahkan kelas serta distribusi *data training*.


4.9. Interpretation dan Evaluation

Tahapan terakhir merupakan hasil evaluasi setelah menggunakan model SVM pada data operasi *caesar*. Berikut performa evaluasi setiap akurasi data pelatihan pada masing-masing kernel dapat dilihat Tabel 4 di bawah ini.

Tabel 4. Nilai Akurasi Data Pelatihan Setiap Kernel

No	Jenis Kernel	Akurasi
1.	RBF	82.64%
2.	<i>Sigmoid</i>	68.07%
3.	<i>Polynomial</i>	82.58%
4.	<i>Linear</i>	79.38%

Dapat diperhatikan pada Tabel 4, bahwa nilai kinerja pelatihan model SVM berada pada kisaran 68% hingga 83%. Setiap kernel menunjukkan performa yang relatif tidak jauh berbeda, sehingga perbedaan kinerja antar kernel tidak terlalu signifikan. Adapun nilai dengan akurasi tinggi diperoleh pada *kernel* RBF sebesar 82.64%. Sedangkan, nilai akurasi terendah dimiliki oleh kernel *sigmoid* sebesar 68.07%.




Gambar 3. Confusion Matrix

Berdasarkan *confusion matrix* pada Gambar 3, ditampilkan keseluruhan kinerja hasil pengujian terhadap 721 data uji untuk masing-masing kernel SVM yang telah dilatih sebelumnya. Berikut ini merupakan hasil evaluasi performa model dari masing-masing kernel, dapat dilihat pada Tabel 5.

Tabel 5. Performa Prediksi Melalui Data Pengujian


Kernel	Akurasi	Presisi	Recall	F1Score
<i>Linear</i>	78.92%	76.26%	83.89%	79.89%
RBF	83.36%	82.43%	84.72%	83.56%
<i>Sigmoid</i>	65.05%	64.67%	66.11%	65.38%
<i>Poly</i>	82.39%	81.40%	83.89%	82.63%

Kinerja model klasifikasi dievaluasi menggunakan *confusion matrix*. Pada tahap pengujian, kernel RBF menunjukkan performa terbaik dengan akurasi sebesar 83,36%, sedikit lebih tinggi dibandingkan akurasi pada data pelatihan sebesar 82,64%. Hal ini menunjukkan bahwa model memiliki kemampuan generalisasi yang baik serta keseimbangan antara data latih dan data uji. Kemudian, kernel *polynomial* juga menunjukkan performa yang baik dengan akurasi data latih sebesar 82,58% dan akurasi data uji sebesar 82,39%, yang mencerminkan hasil yang stabil dan konsisten. Dapat dilihat perbandingan akurasi model saat pelatihan dan juga saat pengujian pada Gambar 4.



Gambar 4. Akurasi Model Setiap Kernel

Penelitian ini dilengkapi dengan kurva ROC sebagai grafik klasifikasi biner dengan dua nilai seperti Gambar 5 di bawah ini. Kurva ROC mendekati sudut kiri atas, menunjukkan model memiliki *False Positive Rate* (FPR) rendah dan *True Positive Rate* (TPR) tinggi.



Gambar 5. Kurva ROC-AUC

Berdasarkan hasil kurva ROC-AUC tersebut keempat gambar itu menghasilkan nilai *Area Under The Curve* (AUC) untuk hasil yang lebih rinci dibandingkan hanya menggunakan akurasi. Masing-masing nilai AUC disetiap kernel yaitu kernel *linear* 88.01%, kernel *polynomial* sebesar 89.28%, untuk kernel RBF sebesar 89.86%, dan pada kernel *sigmoid* sebesar 70.19%.

Keutamaan penggunaan algoritma *Support Vector Machine* (SVM) ada pada kernel RBF secara khusus dilihat pada *confusion matrix* dan nilai AUC yang sama memiliki hasil performa tinggi dibandingkan dengan kernel lainnya. Hal ini menunjukkan bahwa kesesuaian dari SVM dalam mengatasi masalah data kompleks. Meskipun, saat ini peneliti mengkaji analisis ini dengan memperoleh performa model pengujian 83.36% dengan kernel RBF. Tetapi, algoritma ini dapat dikaji kembali dengan pengaturan nilai parameter yang lebih tepat untuk setiap kernel dan disesuaikan kembali dengan karakteristik dari data dan tujuan penelitian agar mendapatkan kinerja model yang lebih baik.

5. KESIMPULAN DAN SARAN

Berdasarkan penelitian yang sudah dianalisis, menghasilkan variasi performa model dari setiap algoritma *Support Vector Machine* (SVM) terhadap kernel yang dikaji. Hasilnya dilihat dari perbandingan akurasi dari data latih dan data uji. Untuk kernel *linear* pada 79.38% dan 78.92%, kernel *polynomial* 82.58% dan 82.39%, kernel RBF dengan 82.64% dan 83.36%, serta kernel *sigmoid* 68.07% dan 65.05%. Hal ini dimaksud bahwa kernel RBF lebih efektif dengan susunan penggunaan parameter $C = 1.0$ dan $\Gamma = 2$ dengan hasil 83,36%, sedikit lebih tinggi dibandingkan akurasi pada data pelatihan sebesar 82,64%. Hal ini menunjukkan bahwa model memiliki kemampuan generalisasi yang baik serta keseimbangan antara data latih dan data uji. Selain itu, kernel *polynomial* juga menunjukkan performa yang baik dengan akurasi data latih sebesar 82,58% dan akurasi data uji sebesar 82,39%, yang mencerminkan hasil yang stabil dan konsisten. Penggunaan kurva ROC-AUC juga membantu penentuan antara kelas positif dan kelas negatif dari suatu proses analisis agar lebih baik dalam pengkategorian pada data aktual yang diuji agar diprediksi dengan benar. Masing-masing nilai AUC disetiap kernel yaitu kernel *linear* 88.01%, kernel *polynomial* sebesar 89.28%, untuk kernel RBF sebesar 89.86%, dan pada kernel *sigmoid* sebesar 70.19%, terlihat nilai performa yang baik pada kernel RBF. Selanjutnya, berdasarkan hasil dari pengembangan SVM pada data *caesar* ini, dapat disarankan agar peneliti di masa depan dapat menggunakan metode algoritma *deep learning* seperti *neural network* dengan arsitektur model seperti *input layer*, *hidden layer*, dan *output layer* dapat memberikan kemampuan pelatihan model terutama dihadapkan dengan data yang bersifat kompleks dan memiliki banyak fitur.

DAFTAR PUSTAKA

- [1] M. Kamaruddin and N. Trianansini, "EFEKTIVITAS SENAM HAMIL TERHADAP KELANCARAN PERSALINAN KALA II PADA IBU INPARTU DI PUSKESMAS BULUPODDO KABUPATEN SINJAI," *Medika Alkhairaat: Jurnal Penelitian Kedokteran dan Kesehatan*, vol. 2, no. 2, pp. 187-191, Sep. 2020, doi: 10.31219/osf.io/sg45d.
- [2] I. Sudarsih, A. Agustin, and A. Ardiansyah, "HUBUNGAN ANTARA KOMPLIKASI KEHAMILAN DAN RIWAYAT PERSALINAN TERHADAP TINDAKAN SECTIO CAESAREA," *J. Penelit. Perawat Prof.*, vol. 5, no. 4, pp. 1567-1576, Nov. 2023, doi: 10.37287/jppp.v5i4.1875.
- [3] L. Y. Armayanti, A. A. I. Nataningrat, and N. M. K. Sumiari Tangkas, "Hubungan Mobilisasi Dini Terhadap Penyembuhan Luka Sectio Caesarea (SC) Di Ruang Nifas Rumah Sakit Umum Daerah Klungkung," *Jurnal Riset Kesehatan*

- Nasional*, vol. 8, no. 1, pp. 69–74, 2024, doi: 10.37294/jrkn.v8i1.562.
- [4] T. N. Herdiani and D. Fitriani, “Pengaruh Teknik Relaksasi Napas Dalam Terhadap Nyeri Post Sectio Caesarea di RSUD Rupit,” *Madago Nursing Journal*, vol. 4, no. 1, pp. 18–26, Jun. 2023, doi: 10.33860/mnj.v4i1.2157.
- [5] P. Amalia, Y. Hermayanti, and S. Sukmawati, “FOOT MASSAGE THERAPY MENGGUNAKAN MINYAK ZAITUN UNTUK MENGURANGI NYERI POST SECTIO CAESAREA: CASE REPORT,” *SJRI*, vol. 3, no. 9, pp. 4359–4369, Sep. 2024.
- [6] M. Septiana and A. Sapitri, “Faktor-Faktor Yang Berhubungan Dengan Persalinan Sectio Caesarea,” *Lentera Perawat*, vol. 1, no. 2, pp. 88–97, Jun. 2022, doi: 10.52235/lp.v1i2.143.
- [7] N. Janah, I. W. Desiyanti and A. Sunarmi, “Faktor yang Mempengaruhi Terjadinya Infeksi Daerah Operasi (IDO) Pada Pasien Post Operasi Sectio Caesarea di Rumah Sakit Umum Daerah Labuha,” *Jurnal Pendidikan Tambusai*, vol. 9, no. 1, pp. 3856–3866, 2025.
- [8] L. Siagian, M. Anggraeni, and G. K. Pangestu, “HUBUNGAN ANTARA LETAK JANIN, PREEKLAMPSIA, KETUBAN PECAH DINI DENGAN KEJADIAN SECTIO CAESARIA DI RS YADIKA KEBAYORAN LAMA TAHUN 2021,” *SENTRI: Jurnal Riset Ilmiah*, vol. 2, no. 4, pp. 1107–1119, 2023, doi: 10.55681/sentri.v2i4.707.
- [9] Pittara. “Plasenta Previa,” Gejala, Penyebab, dan Pengobatan – Alodoter. <https://www.alodokter.com/plasenta-previa>, [accessed: Apr. 04, 2025].
- [10] P. Sari Ramadhan, M. Yolanda Nasution, and S. Julianita, “Penerapan Apriori Dalam Menganalisa Strategi Penjualan Perlengkapan,” *Jurnal Teknologi Sistem Informasi dan Sistem Komputer TGD*, vol. 8, no. 1, pp. 99–107, 2025, doi: 53513/jsk.v8i1.10743.
- [11] Vizhiyarasi S, Matheswari S, Meaga J, and Nishani S, “Predicting Childbirth Modes: A Comparative Analysis of Machine Learning Algorithm,” *International Journal of Scientific Research and Technology*, vol. 2, no. 3, 2025, doi: 10.5281/ZENODO.15078387.
- [12] A. A. Abdillah, Azwardi, S. Permana, I. Susanto, F. Zainuri, and S. Arifin, “Performance Evaluation Of Linear Discriminant Analysis And Support Vector Machines To Classify Cesarean Section,” *Eastern-European Journal of Enterprise Technologies*, vol. 5, no. 2–113, pp. 37–43, 2021, doi: 10.15587/1729-4061.2021.242798.
- [13] R. S. Wijaya, A. Qur’ania, and I. Anggraeni, “Klasifikasi Penyakit Cacar Monyet Menggunakan Support Vector Machine (SVM),” *MALCOM: Indonesian Journal of Machine Learning and Computer Science*, vol. 4, no. 4, pp. 1253–1260, Jul. 2024, doi: 10.57152/malcom.v4i4.1417.
- [14] Y. Prasetyo *et al.*, “ANALISIS PERBANDINGAN OPTIMIZER SGD DAN ADAM PADA MODEL CNN UNTUK KLASIFIKASI JAMUR EDIBLE DAN POISONOUS,” *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 9, no. 1, pp. 1348–1354, Jan. 2025, doi: 10.36040/JATI.V9I1.12659.
- [15] D. T. Wilujeng, M. Fatekurohman, and I. M. Tirta, “Analisis Risiko Kredit Perbankan Menggunakan Algoritma K-Nearest Neighbor dan Nearest Weighted K-Nearest Neighbor,” *Indonesian Journal of Applied Statistics*, vol. 5, no. 2, p. 142, 2023, doi: 10.13057/ijas.v5i2.58426.
- [16] I. N. Dita Suardinata, N. Widya Utami, and H. Syakh Alam, “PREDIKSI POTENSI KEBANGKRUTAN PADA PERUSAHAAN YANG TERDAFTAR DI BEI MENGGUNAKAN ALGORITMA BACKPROPAGATION NEURAL NETWORK,” *JATI (Jurnal Mahasiswa Teknik Informatika)*, vol. 8, no. 1, pp. 748–755, 2024, doi: 10.36040/jati.v8i1.8826.
- [17] A. Supriyadi Sunge, E. Abdurachman, Y. Heryadi, and I. H. Kartowisatro, “PERFORMANCE COMPARISON OF DECISION TREE, RANDOM FOREST, AND XGBOOST MODELS; AND ITS INTERPRETABILITY USING SHAP FOR RECOGNIZING THE NECESSITY OF CAESAREANS SECTION OF CHILDBIRTH,” *J Theor Appl Inf Technol*, vol. 15, no. 9, 2023, doi: 10.5061/drya.