

---

## Perbandingan Seleksi Fitur *Forward Selection* dan *Backward Elimination* pada Algoritma *Support Vector Machine*

Wandayana Nur'Amanah Suharmin<sup>1</sup>, Isran K. Hasan<sup>2</sup>, Nisky Imansyah Yahya<sup>3</sup>

wndaynasuharmin@gmail.com<sup>1</sup>, isran.hasan@ung.ac.id<sup>2</sup>, nisky@ung.ac.id<sup>3</sup>

<sup>1,2,3</sup> Universitas Negeri Gorontalo

---

### Informasi Artikel

Diterima : 23 Feb 2025

Direvisi : 25 Apr 2025

Disetujui : 30 Apr 2025

---

### Kata Kunci

Support Vector Machine, Seleksi Fitur, Forward Selection, Backward Elimination, Indeks Kedalaman Kemiskinan

---

### Abstrak

Support Vector Machine (SVM) adalah metode klasifikasi yang efektif dan kuat, terutama ketika diterapkan pada data berdimensi tinggi. Namun, data berdimensi tinggi sering kali mengandung fitur-fitur yang tidak relevan, sehingga kinerja SVM menjadi tidak optimal. Oleh karena itu, diperlukan proses seleksi fitur sebagai solusi untuk mengoptimalkan kinerja klasifikasi dengan menghilangkan fitur-fitur yang tidak relevan dan berlebihan dari dataset asli. Penelitian ini bertujuan membandingkan metode seleksi fitur *Forward Selection* dan *Backward Elimination* pada algoritma *Support Vector Machine* dalam klasifikasi data Indeks Kedalaman Kemiskinan di Provinsi Papua. Hasil penelitian menunjukkan bahwa penerapan *Support Vector Machine* dengan seleksi fitur *Forward Selection* menghasilkan akurasi klasifikasi sebesar 93%, sedangkan dengan seleksi fitur *Backward Elimination* mencapai 97%. Berdasarkan hasil akurasi klasifikasi tersebut, dapat disimpulkan bahwa penerapan *Support Vector Machine* dengan seleksi fitur *Backward Elimination* memberikan kinerja yang lebih baik dibandingkan dengan *Forward Selection*.

---

### Keywords

*Support Vector Machine, Feature Selection, Forward Selection, Backward Elimination, Poverty Depth Index*

---

### Abstract

*Support Vector Machine (SVM) is an effective and robust classification method, particularly when applied to high-dimensional data. However, high-dimensional data often contain irrelevant features that can lead to suboptimal SVM performance. Therefore, a feature selection process is necessary to optimize classification performance by eliminating irrelevant and redundant features from the original dataset. This research aims to compare the Forward Selection and Backward Elimination feature selection methods within the Support Vector Machine Algorithm for classification using the Poverty Depth Index data in Papua Province. The results indicated that applying the Support Vector Machine with Forward Selection feature selection achieved a classification accuracy of 93%, whereas Backward Elimination feature selection achieved a classification accuracy of 97%. Based on these classification accuracy results, it can be concluded that applying Support Vector Machine with Backward Elimination feature selection results in better performance than Forward Selection.*

## A. Pendahuluan

Kemiskinan merupakan salah satu masalah sosial terbesar, terutama di negara-negara berkembang seperti Indonesia. Berdasarkan data dari Badan Pusat Statistik tahun 2023, Provinsi Papua menunjukkan persentase penduduk miskin tertinggi di Indonesia mencapai 26,03% dengan jumlah penduduk miskin sekitar 915,15 ribu jiwa. Untuk menilai tingkat kemiskinan, penting untuk tidak hanya memperhatikan jumlah dan persentase penduduk miskin, tetapi juga mempertimbangkan indikator lain seperti indeks kedalaman kemiskinan [1]. Indeks kedalaman kemiskinan adalah indikator yang menunjukkan seberapa jauh rata-rata pengeluaran individu miskin berada di bawah garis kemiskinan [2]. Berdasarkan data Badan Pusat Statistik tahun 2023, Indeks kedalaman kemiskinan di Provinsi Papua mengalami peningkatan yang signifikan antara Maret 2022 dan September 2022, naik dari 6,164% menjadi 7,285%. Kenaikan ini mencerminkan tingkat kemiskinan yang semakin parah di kalangan penduduk miskin.

Akses terhadap informasi atau data tentang kemiskinan menjadi hal yang penting dalam mendukung upaya penanggulangan kemiskinan. Data yang tersedia dapat dianalisis untuk membantu pemerintah dalam membuat kebijakan yang tepat untuk mengatasi masalah kemiskinan. Oleh karena itu, diperlukan teknologi yang dapat mempercepat dan meningkatkan efisiensi proses pengambilan keputusan, salah satunya melalui penerapan *machine learning*.

*Machine learning* merupakan cabang dari kecerdasan buatan yang menyajikan kemampuan komputer yang mampu belajar sendiri dari data tanpa adanya intervensi langsung dari manusia [3]. Dalam *machine learning* terdapat tiga metode pembelajaran salah satunya adalah *supervised learning*. Salah satu contoh masalah komputasi yang dapat diselesaikan menggunakan *supervised learning* yaitu klasifikasi. Tujuan utama dari klasifikasi adalah memprediksi label kelas dari data yang tidak diketahui label kelasnya [4]. Metode klasifikasi yang memiliki tingkat efisiensi tinggi dan mampu mencapai kinerja klasifikasi yang lebih unggul dibandingkan dengan metode klasifikasi lainnya adalah *Support Vector Machine* (SVM) [5]. Hal ini dibuktikan dengan hasil penelitian sebelumnya oleh Fauziah dkk (2022) [6] yang membandingkan metode *K-Nearest Neighbor* (KNN) dan SVM dalam mengklasifikasikan data kemiskinan Provinsi Papua dan menghasilkan hasil akurasi tertinggi pada metode SVM sebesar 93% dibandingkan dengan metode KNN sebesar 58%. SVM adalah metode klasifikasi yang efektif dan kuat, terutama ketika diimplementasikan pada data yang berdimensi tinggi. Namun, data berdimensi tinggi sering kali memuat fitur-fitur yang tidak relevan yang membuat SVM tidak bekerja dengan akurat [7]. Fitur yang tidak relevan atau berlebihan dapat menurunkan kinerja model dan menyebabkan penurunan akurasi klasifikasi [8]. Oleh karena itu, diperlukan solusi yang efektif untuk mengoptimalkan kinerja klasifikasi, yaitu dengan menghapus fitur yang tidak relevan dan berlebihan dari dataset asli melalui penerapan teknik seleksi fitur [9].

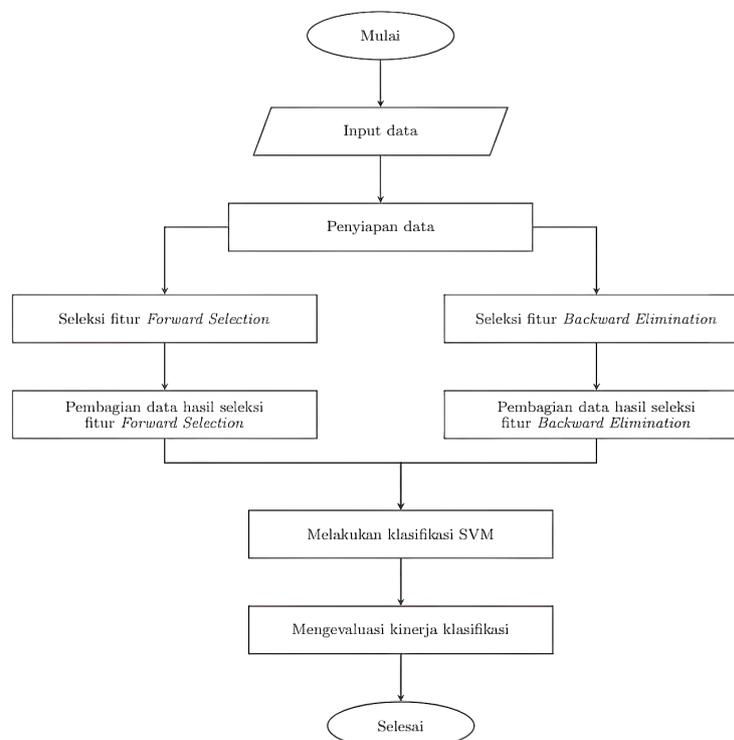
Seleksi fitur yang sering digunakan dalam kasus klasifikasi adalah seleksi fitur *Forward Selection* dan *Backward Elimination* [10]. Penggunaan seleksi fitur *Forward Selection* maupun *Backward Elimination* dapat meningkatkan performa hasil klasifikasi. Hal ini dibuktikan dari beberapa penelitian terdahulu diantaranya yaitu penelitian oleh Sasongko dan Arifin (2019) [11] untuk klasifikasi jalur minat SMA di dua sekolah. Pada penelitian tersebut *Forward Selection* mampu

meningkatkan kinerja model pada Algoritma SVM dengan tingkat akurasi sebesar 99,29% dan 95,17% untuk masing-masing sekolah. Adapun penelitian yang dilakukan oleh Purnomo dkk. (2020) [12] diperoleh hasil bahwa *Naive Bayes* dengan *Forward Selection* menghasilkan nilai akurasi yang tinggi sebesar 95,44% dibandingkan *Naive Bayes* tanpa *Forward Selection* sebesar 84,29%. Penelitian lain oleh Amilia dkk. (2021) [13] menghasilkan peningkatan performa klasifikasi karena menerapkan *Backward Elimination* dengan nilai akurasi awal sebesar 94,56% menjadi 98,33%. Penelitian oleh Byna dan Anisa (2018) [14] menambahkan seleksi fitur *Backward Elimination* pada kasus klasifikasi penyakit gagal jantung dan menghasilkan akurasi yang lebih tinggi pada metode SVM dengan *Backward Elimination* sebesar 90,16% dibandingkan SVM tanpa *Backward Elimination* sebesar 81,62%.

Berdasarkan penelitian-penelitian sebelumnya dapat diketahui bahwa Seleksi Fitur *Forward Selection* dan *Backward Elimination* memiliki kelebihan masing-masing dalam meningkatkan hasil akurasi klasifikasi. Oleh karena itu, penelitian ini bertujuan untuk membandingkan kedua seleksi fitur tersebut untuk mengetahui seleksi fitur mana yang lebih baik dalam meningkatkan performa hasil klasifikasi indeks kedalaman kemiskinan di Provinsi Papua pada Algoritma *Support Vector Machine*.

## B. Metode Penelitian

Penelitian ini bertujuan untuk membandingkan dua metode seleksi fitur guna menentukan efektivitasnya dalam meningkatkan performa klasifikasi pada algoritma *Support Vector Machine*. Penelitian ini menggunakan bahasa pemrograman *python* dalam proses pengolahan data. Berikut merupakan diagram tahapan penelitian yang dilakukan.



**Gambar 1. Tahapan Penelitian**

## 1. Dataset

Data yang digunakan pada penelitian ini adalah data sekunder berupa data indeks kedalaman kemiskinan dan faktor-faktor yang mempengaruhi indeks kedalaman kemiskinan pada 29 Kabupaten/Kota di Provinsi Papua tahun 2018 sampai 2022 yang diperoleh dari website Badan Pusat Statistik (BPS) yang terdiri dari 9 variabel X dan 1 variabel Y. Variabel penelitian yang digunakan dapat dilihat pada tabel berikut ini.

**Table 1. Variabel Penelitian**

Variabel	Keterangan	Skala
Y	Indeks Kedalaman Kemiskinan	Rasio
X1	Jumlah Penduduk Miskin	Rasio
X2	Garis Kemiskinan	Rasio
X3	Tingkat Pengangguran Terbuka	Rasio
X4	Angka Harapan Hidup	Rasio
X5	Harapan Lama Sekolah	Rasio
X6	Rata-rata Lama Sekolah	Rasio
X7	Pengeluaran Per Kapita	Rasio
X8	Produk Domestik Regional Bruto	Rasio
X9	Tingkat Partisipasi Angkatan Kerja	Rasio

## 2. Penyiapan Data

Tahap penyiapan data atau yang dikenal sebagai pra pemrosesan data, dilakukan untuk mempersiapkan data agar siap untuk proses analisis atau pengolahan lebih lanjut. Berikut ini merupakan beberapa tahapan penyiapan data yang dilakukan.

### a. Diskretisasi

Menurut Heryadi dan Wahyono (2020) [15], klasifikasi bertujuan untuk memprediksi variabel target yang memiliki tipe data kategorik. Oleh karena itu, variabel target (Y) dari data penelitian ini yakni indeks kedalaman kemiskinan yang semula bertipe data numerik diubah menjadi data kategorik (diskretisasi) dengan dua kategori yaitu rendah dan tinggi berdasarkan nilai rata-rata. Data nilai indeks kedalaman kemiskinan yang memiliki nilai kurang dari nilai rata-rata akan dikategorikan rendah dan jika nilainya lebih dari sama dengan nilai rata-rata akan dikategorikan tinggi [2].

### b. Encoding

Dalam konteks *machine learning*, *encoding* digunakan untuk mengubah data kategorikal menjadi bentuk yang dapat dipahami dan dapat diproses oleh algoritma, yaitu dengan mengubah label atau kelas data menjadi representasi numerik. Hal ini bertujuan agar model *machine learning* dapat memahami dan bekerja dengan data tersebut secara efektif. Pada penelitian ini kelas data dengan kategori rendah menjadi 0 dan kategori tinggi menjadi 1.

### c. *Rescaling*

*Rescaling* atau penskalaan fitur bertujuan agar setiap fitur input ( $X$ ) memiliki kisaran yang sama. Metode *rescaling* yang digunakan adalah *min-max scaling* atau normalisasi data dengan menggunakan bantuan fungsi *MinMaxScaler* yang disediakan oleh *scikit-learn* dalam Aplikasi *Jupyter Notebook*. Normalisasi data adalah proses yang mengubah nilai-nilai dalam dataset sehingga memiliki skala yang seragam dengan memastikan semua nilai dalam fitur-fitur berada dalam rentang 0 hingga 1.

### 3. *Forward Selection*

Proses seleksi fitur berdampak langsung pada kinerja dan akurasi klasifikasi. Algoritma seleksi fitur menghilangkan fitur-fitur yang tidak relevan dan berlebihan dari kumpulan data asli untuk meningkatkan akurasi klasifikasi [16]. *Forward Selection* merupakan bagian dari metode seleksi fitur kategori *wrapper*. Dalam pendekatan metode *wrapper* ini, dilakukan pemilihan subset fitur terbaik yang memberikan akurasi tertinggi pada model [17]. Pada proses *Forward Selection*, iterasi dimulai dengan model kosong atau tanpa variabel dan kemudian secara bertahap, satu per satu variabel dimasukkan hingga mencapai suatu kriteria tertentu [18]. Dalam setiap iterasi, akan ditambahkan fitur yang memiliki pengaruh paling signifikan dalam meningkatkan performa model [19].

### 4. *Backward Elimination*

*Backward Elimination* merupakan metode seleksi fitur kategori *wrapper*, yang prosesnya berlawanan dengan *Forward Selection*. *Backward Elimination* dimulai dengan menguji semua fitur terlebih dahulu, kemudian menghapus fitur-fitur yang dianggap tidak relevan secara bertahap [20]. Metode penyeleksian fitur ini bekerja secara iteratif dengan umpan balik berulang, dimana pada setiap iterasi *Backward Elimination* akan menghapus satu fitur yang tidak relevan dan menghasilkan subset fitur baru [21].

### 5. Pembagian Data

Langkah ini merupakan langkah awal sebelum melangkah ke proses klasifikasi SVM. Data dibagi menjadi dua bagian yaitu *data training* dan *data testing*. *data training* memberikan dasar untuk membantu membangun model dan mengumpulkan pengetahuan agar dapat mengklasifikasikan data baru yang belum pernah dilihat sebelumnya. Kemudian model yang telah diperoleh akan diuji menggunakan *data testing*. Pengujian pada *data testing* memberikan gambaran seberapa baik model SVM dapat melakukan prediksi pada data baru. Pembagian data pada penelitian ini dilakukan dengan pemilihan secara acak berdasarkan sistem, dengan proporsi 80% dan 20% untuk masing-masing data.

### 6. *Klasifikasi SVM*

Proses klasifikasi SVM pada penelitian ini menggunakan kernel RBF. Pemilihan kernel pada SVM sangat penting dilakukan karena kernel yang dipilih akan mempengaruhi kemampuan model untuk menemukan fungsi pemisah (klasifikasi) yang optimal di dalam ruang fitur. Pada kernel RBF parameter penting yang dapat mempengaruhi kinerja model adalah parameter *cost* ( $C$ ) dan *gamma*

( $\gamma$ ). Parameter C dalam SVM berfungsi sebagai pengoptimalan SVM untuk menghindari kesalahan klasifikasi pada setiap sampel dalam dataset pelatihan. Parameter  $\gamma$  menentukan seberapa jauh pengaruh satu sampel data pelatihan terhadap pembentukan batas keputusan (*decision boundary*) dalam model SVM.

## 7. Evaluasi Kinerja

Langkah terakhir adalah melakukan evaluasi hasil klasifikasi SVM dengan menggunakan *confusion matrix*. *Confusion matrix* digunakan untuk menilai performa atau kinerja dari hasil klasifikasi [22]. *Confusion Matrix* memuat informasi berupa perbandingan hasil klasifikasi seharusnya dengan hasil klasifikasi yang diprediksi oleh sistem. *Confusion matrix* diperoleh dari hasil pengujian model menggunakan data *testing* yang bertujuan untuk melihat seberapa baik model dapat melakukan prediksi pada data baru. Tabel *confusion matrix* disajikan pada tabel berikut ini.

**Table 2. Confusion Matrix**

		Kelas Prediksi	
		Positif	Negatif
Kelas Aktual	Positif	TP	FP
	Negatif	FN	TN

## C. Hasil dan Pembahasan

Setelah melalui proses penyiapan data, selanjutnya dilakukan proses seleksi fitur *Forward Selection* dan *Backward Elimination*. Berikut ini disajikan tabel hasil masing-masing seleksi fitur.

### 1. Seleksi Fitur Forward Selection

**Table 3. Hasil Seleksi Fitur Forward Selection**

Iterasi	Jumlah Fitur	Fitur	Skor
Pertama	1	X5	0,7172
Kedua	2	X5, X6	0,7310
Ketiga	3	X5, X6, X8	0,7517
Keempat	4	X4, X5, X6, X8	0,7448
Kelima	5	X1, X4, X5, X6, X8	0,7724
Keenam	6	X1, X3, X4, X5, X6, X8	0,7862
Ketujuh	7	X1, X3, X4, X5, X6, X8, X9	0,7862
Kedelapan	8	X1, X2, X3, X4, X5, X6, X8, X9	0,7862
Kesembilan	9	X1, X2, X3, X4, X5, X6, X7, X8, X9	0,7793

Seleksi Fitur *Forward Selection* bekerja secara iteratif untuk memilih fitur-fitur yang meningkatkan performa algoritma klasifikasi. Pada setiap iterasi, ditambahkan 1 fitur secara bertahap ke dalam model. Setiap proses dari *Forward Selection* akan menghasilkan kombinasi fitur yang memiliki skor. Skor tersebut menunjukkan performa atau kinerja dari model yang membantu dalam menentukan fitur-fitur terpilih. Kombinasi fitur yang memiliki skor tertinggi akan dipilih dan merupakan hasil dari seleksi fitur *Forward Selection*.

Pemilihan fitur difokuskan pada iterasi yang menghasilkan performa model yang baik. Pada proses *Forward Selection* ini dipilih kombinasi fitur pada iterasi keenam karena kombinasi fitur pada iterasi tersebut memiliki skor atau akurasi tertinggi. Pada iterasi tersebut, model menggabungkan 6 fitur dan mencapai tingkat akurasi sebesar 78.62%. Enam fitur terpilih dari proses seleksi fitur *Forward Selection* diantaranya yaitu X1, X3, X4, X5, X6 dan X8. Fitur X2, X7 dan X9 tidak terpilih karena penambahan fitur-fitur tersebut dalam model tidak menghasilkan peningkatan pada performa model.

## 2. Seleksi Fitur *Backward Elimination*

**Table 4. Hasil Seleksi Fitur *Backward Elimination***

Iterasi	Jumlah Fitur	Fitur	Akurasi
Pertama	9	X1, X2, X3, X4, X5, X6, X7, X8, X9	0,7793
Kedua	8	X1, X2, X3, X4, X5, X6, X7, X8	0,7862
Ketiga	7	X1, X2, X3, X4, X5, X6, X7	0,7862
Keempat	6	X1, X3, X4, X5, X6, X7	0,7862
Kelima	5	X1, X3, X5, X6, X7	0,7931
Keenam	4	X1, X3, X6, X7	0,7862
Ketujuh	3	X1, X3, X6	0,8
Kedelapan	2	X1, X6	0,7793
Kesembilan	1	X6	0,7034

*Backward Elimination* merupakan metode penyeleksian fitur yang berkebalikan dengan *Forward Selection*. Proses iterasi pada *Backward Elimination* dimulai dengan memasukkan seluruh fitur ke dalam model. Selanjutnya, secara iteratif fitur-fitur yang memberikan kontribusi paling kecil terhadap model dieliminasi satu per satu. Sama halnya dengan *Forward Selection*, setiap proses pada *Backward Elimination* akan menghasilkan kombinasi fitur yang memiliki skor. Skor tersebut menunjukkan kinerja dari model yang membantu dalam menentukan fitur-fitur terpilih. Kombinasi fitur yang memiliki skor tertinggi akan dipilih dan merupakan hasil dari seleksi fitur *Backward Elimination*.

Pemilihan fitur difokuskan pada iterasi yang menghasilkan performa model yang baik. Pada proses *Backward Elimination* ini dipilih kombinasi fitur pada iterasi ketujuh karena kombinasi fitur pada iterasi tersebut menghasilkan skor atau akurasi tertinggi. Pada iterasi tersebut, model mencapai tingkat akurasi sebesar 80% dengan menggabungkan 3 fitur. Tiga fitur terpilih dari proses seleksi fitur *Backward Elimination* diantaranya yaitu X1, X3 dan X6. Fitur X2, X4, X5, X7, X8 dan X9 dihapus karena kontribusi fitur-fitur tersebut terhadap performa model tidak signifikan. Performa model yang dihasilkan lebih baik ketika tidak menggunakan fitur-fitur tersebut dalam model. Hal ini dapat dilihat pada performa model yang dihasilkan dari keseluruhan kombinasi fitur pada setiap iterasi.

## 3. Klasifikasi dan Evaluasi

Selanjutnya, fitur-fitur terpilih dari masing-masing hasil seleksi fitur akan digunakan dalam proses klasifikasi SVM menggunakan kernel RBF dengan parameter  $C = 1$  dan  $\gamma = 1$ . Kernel RBF (*Radial Basis Function*) dipilih karena

kemampuannya dalam menangani data non-linear dengan memetakan data ke dalam dimensi yang lebih tinggi. Parameter C berfungsi sebagai pengontrol regulasi dalam model, di mana nilai C yang lebih besar cenderung mengurangi jumlah kesalahan klasifikasi tetapi berisiko menyebabkan *overfitting*. Sementara itu, parameter  $\gamma$  menentukan seberapa jauh pengaruh satu titik data terhadap titik lainnya dalam ruang fitur, yang dapat mempengaruhi kompleksitas dan kapasitas generalisasi model. Dengan konfigurasi ini, model dapat menghasilkan performa klasifikasi yang optimal.

Setelah melakukan proses klasifikasi, dilakukan evaluasi pada hasil klasifikasi SVM dengan menggunakan *confusion matrix*. Berikut ini disajikan tabel *confusion matrix* hasil klasifikasi SVM dengan menggunakan seleksi fitur *Forward Selection* dan *Backward Elimination*.

**Table 5. Hasil Confusion Matrix SVM dengan Forward Selection**

		Kelas Prediksi	
		Rendah	Tinggi
Kelas Aktual	Rendah	17	1
	Tinggi	1	10

Tabel di atas menyajikan hasil klasifikasi SVM menggunakan data *output* dari seleksi fitur *Forward Selection*. Dari total 18 data yang sebenarnya termasuk kelas rendah, terdapat 17 data yang diklasifikasi atau diprediksi dengan benar sebagai kelas rendah dan 1 data yang salah diprediksi sebagai kelas tinggi. Sementara dari total 11 data yang sebenarnya termasuk kelas tinggi, terdapat 10 data yang diklasifikasi atau diprediksi dengan benar sebagai kelas tinggi dan 1 data salah diprediksi sebagai kelas rendah. Dengan demikian, diketahui bahwa hanya terdapat 2 data yang misklasifikasi atau yang tidak dapat diklasifikasikan dengan benar.

**Table 6. Hasil Confusion Matrix SVM dengan Backward Elimination**

		Kelas Prediksi	
		Rendah	Tinggi
Kelas Aktual	Rendah	18	0
	Tinggi	1	10

Tabel di atas menunjukkan hasil klasifikasi SVM menggunakan data *output* dari seleksi fitur *Backward Elimination*. Dari total 18 data yang sebenarnya termasuk kelas rendah, semuanya berhasil diklasifikasi atau diprediksi dengan benar sebagai kelas rendah dan tidak ada data yang salah diprediksi sebagai kelas tinggi. Sementara dari total 11 data yang sebenarnya termasuk kelas tinggi, terdapat 10 data yang diklasifikasi atau diprediksi dengan benar sebagai kelas tinggi dan 1 data yang salah diprediksi sebagai kelas rendah. Dengan demikian, diketahui bahwa hanya terdapat 1 data yang misklasifikasi atau yang tidak dapat diklasifikasikan dengan benar.

Hasil dari *confusion matrix* akan digunakan untuk mengevaluasi kinerja hasil klasifikasi dengan menghitung nilai akurasi, presisi, dan recall. Berikut ini

disajikan tabel hasil perbandingan evaluasi klasifikasi SVM menggunakan *Forward Selection* dan *Backward Elimination*.

**Table 7. Hasil Perbandingan Evaluasi Kinerja Klasifikasi**

Algoritma	Akurasi	Presisi	Recall
SVM + <i>Forward Selection</i>	93%	92,5%	92,5%
SVM + <i>Backward Elimination</i>	97%	97,5%	95,5%

Dapat dilihat pada tabel di atas bahwa Algoritma SVM dengan seleksi fitur *Forward Selection* menghasilkan tingkat akurasi sebesar 93%, yang berarti algoritma SVM berhasil memprediksi kategori kelas rendah dan tinggi dengan tingkat keakuratan mencapai 93%. Sementara itu, algoritma SVM dengan seleksi fitur *Backward Elimination* menghasilkan akurasi sebesar 97%, yang menunjukkan bahwa algoritma SVM mampu memprediksi kategori kelas rendah dan tinggi dengan tingkat keakuratan mencapai 97%.

#### D. Simpulan

Setelah dilakukannya analisis dan pembahasan hasil, dapat disimpulkan bahwa penerapan *Support Vector Machine* dengan seleksi fitur mampu menghasilkan performa model yang baik dengan tingkat akurasi yang tinggi dalam mengklasifikasikan indeks kedalaman kemiskinan di Provinsi Papua. Algoritma yang memiliki tingkat akurasi tertinggi adalah algoritma SVM dengan seleksi fitur *Backward Elimination*, yang mencapai akurasi sebesar 97%. Hal ini menunjukkan bahwa model yang dihasilkan memiliki kemampuan yang sangat baik dalam melakukan klasifikasi atau pengelompokan data ke dalam kategori yang sesuai. Berdasarkan hasil akurasi klasifikasi tersebut, dapat disimpulkan bahwa penerapan *Support Vector Machine* dengan seleksi fitur *Backward Elimination* menghasilkan kinerja yang lebih baik dibandingkan dengan *Forward Selection*. Saran untuk penelitian selanjutnya adalah mencoba menggunakan metode seleksi fitur dari kategori lain selain *wrapper*, seperti metode seleksi fitur dalam kategori *filter* atau *embedded*, untuk membandingkan efisiensi dan memberikan alternatif yang lebih fleksibel dalam memilih fitur yang paling relevan.

#### E. Ucapan Terima Kasih

Terima kasih kepada dosen pembimbing dan teman-teman yang telah membantu dalam proses penelitian ini.

#### F. Referensi

- [1] U. Habib and H. Wahyudi, "Indeks Kedalaman Kemiskinan Sebelum dan Saat Pandemi Covid-19 di Indonesia," *Stud. Ekon. dan Kebijak. Publik*, vol. 1, no. 1, pp. 59–72, 2022, doi: 10.35912/sekp.v1i1.1424.
- [2] S. E. Utami and Y. Setyawan, "Klasifikasi Kabupaten/Kota Di Indonesia Berdasarkan Tingkat Kedalaman Dan Keparahan Kemiskinan Menggunakan Naïve Bayes Classifier Dan K-Nearest Neighbor," *Pros. SNAST (Seminar Nas.*

- Apl. Sains Teknol.*, pp. F17-25, 2022, doi: 10.34151/prosidingsnast.v8i1.4181.
- [3] T. Wahyono, *Fundamental of Python for Machine Learning: Dasar-Dasar Pemrograman Python untuk Machine Learning dan Kecerdasan Buatan*, no. September 2018. 2018.
- [4] S. Lonang and D. Normawati, "Klasifikasi Status Stunting Pada Balita Menggunakan K-Nearest Neighbor Dengan Feature Selection Backward Elimination," *J. MEDIA Inform. BUDIDARMA*, vol. 6, no. 1, p. 49, Jan. 2022, doi: 10.30865/mib.v6i1.3312.
- [5] N. T. Romadloni and H. F. Pardede, "Seleksi Fitur Berbasis Pearson Correlation Untuk Optimasi Opinion Mining Review Pelanggan," *J. RESTI (Rekayasa Sist. dan Teknol. Informasi)*, vol. 3, no. 3, pp. 505–510, 2019, doi: 10.29207/resti.v3i3.1189.
- [6] Fauziah, M. A. Tiro, and Ruliana, "Comparison of k-Nearest Neighbor (k-NN) and Support Vector Machine (SVM) Methods for Classification of Poverty Data in Papua," *ARRUS J. Math. Appl. Sci.*, vol. 2, no. 2, pp. 83–91, 2022, doi: 10.35877/mathscience741.
- [7] A. Bode, "Support Vector Machine Menggunakan Forward Selection untuk Prediksi Penjualan Obat," *Tecnoscienza*, vol. 3, no. 1, pp. 16–28, 2018.
- [8] A. A. Alhussan *et al.*, "Classification of Diabetes Using Feature Selection and Hybrid Al-Biruni Earth Radius and Dipper Throated Optimization," *Diagnostics*, vol. 13, no. 12, pp. 1–40, 2023, doi: 10.3390/diagnostics13122038.
- [9] S. S. Shreem, S. Abdullah, and M. Z. A. Nazri, "Hybrid feature selection algorithm using symmetrical uncertainty and a harmony search algorithm," *Int. J. Syst. Sci.*, vol. 47, no. 6, pp. 1312–1329, 2016, doi: 10.1080/00207721.2014.924600.
- [10] H. Harafani and H. A. Al-Kautsar, "Meningkatkan Kinerja K-Nn Untuk Klasifikasi Kanker Payudara Dengan Forward Selection," *J. Pendidik. Teknol. dan Kejuru.*, vol. 18, no. 1, pp. 99–110, 2021, doi: 10.23887/jptk-undiksha.v18i1.29905.
- [11] T. B. Sasongko and O. Arifin, "Implementasi Metode Forward Selection pada Algoritma Support Vector Machine (SVM) dan Naive Bayes Classifier Kernel Density (Studi Kasus Klasifikasi Jalur Minat SMA)," *J. Teknol. Inf. dan Ilmu Komput.*, vol. 6, no. 4, pp. 383–388, 2019, doi: 10.25126/jtiik.201961000.
- [12] A. Purnomo, M. A. Barata, M. A. Soeleman, and F. Alzami, "Adding feature selection on Naïve Bayes to increase accuracy on classification heart attack disease," *J. Phys. Conf. Ser.*, vol. 1511, no. 1, pp. 1–6, 2020, doi: 10.1088/1742-6596/1511/1/012001.
- [13] I. R. Amilia, H. Oktavianto, and G. Abdurrahma, "Penerapan Backward Elimination Untuk Seleksi Fitur Pada Algoritma K-Nearest-Neighbour Untuk Klasifikasi Penyakit Gagal Jantung," *J. Apl. Sist. Inf. dan Elektron.*, vol. 3, no. 1, pp. 32–39, 2021.
- [14] A. Byna and N. F. Anisa, "Backward Elimination Untuk Meningkatkan Akurasi Kejadian Stunting Dengan Analisis Algoritma Support Vector Machine," *Din. Kesehat.*, vol. 9, no. 2, 2018.
- [15] Y. Heryadi and T. Wahyono, *Machine Learning: Konsep dan Implementasi*.

- Gava Media, 2020.
- [16] R. Pradeepa and K. Palanivel, "A Survey on Classification of Feature Selection Strategies," *Int. J. Trend Sci. Res. Dev.*, vol. 2, no. 2, pp. 1257–1262, 2018, doi: 10.31142/ijtsrd9632.
- [17] S. S. Hameed, O. O. Petinrin, A. O. Hashi, and F. Saeed, "Filter-wrapper combination and embedded feature selection for gene expression data," *Int. J. Adv. Soft Comput. its Appl.*, vol. 10, no. 1, pp. 90–105, 2018.
- [18] M. F. Nugroho and S. Wibowo, "Fitur Seleksi Forward Selection Untuk Menentukan Atribut Yang Berpengaruh Pada Klasifikasi Kelulusan Mahasiswa Fakultas Ilmu Komputer UNAKI Semarang Menggunakan Algoritma Naive Bayes," *J. Inform. Upgris*, vol. 3, no. 1, pp. 63–70, 2017, doi: 10.26877/jiu.v3i1.1669.
- [19] D. B. C. Prasetyo, P. N. Andono, and C. Supriyanto, "Metode Naive Bayes Classifier dan Forward Selection Untuk Deteksi Berita Hoaks Bahasa Indonesia," vol. 7, no. 3, pp. 1541–1550, 2023, doi: 10.30865/mib.v7i3.6459.
- [20] X. Deng, Y. Li, J. Weng, and J. Zhang, "Feature selection for text classification: A review," *Multimed. Tools Appl.*, vol. 78, no. 3, pp. 3797–3816, 2019, doi: 10.1007/s11042-018-6083-5.
- [21] M. Ary and D. A. F. Rismiati, "Ukuran Akurasi Klasifikasi Penyakit Mesothelioma Menggunakan Algoritma K-Nearest Neighbor dan Backward Elimination," *SATIN - Sains dan Teknol. Inf.*, vol. 5, no. 1, pp. 11–18, 2019, doi: 10.33372/stn.v5i1.444.
- [22] J. R. Maria Navin and R. Pankaja, "Performance Analysis of Text Classification Algorithms using Confusion Matrix," *Int. J. Eng. Tech. Res.*, vol. 6, no. 4, pp. 75–78, 2016, [Online]. Available: [www.erpublication.org](http://www.erpublication.org)