

## Implementasi Metode *Support Vector Machine* (SVM) pada Klasifikasi Status Penerima Bantuan Pangan Non Tunai

Moch. Anjas Aprihartha<sup>1</sup>

<sup>1</sup>Program Studi S1 PJJ Informatika, Fakultas Ilmu Komputer, Universitas Dian Nuswantoro  
e-mail: [anjas.aprihartha@dsn.dinus.ac.id](mailto:anjas.aprihartha@dsn.dinus.ac.id)

### Abstrak

*Dalam Peraturan Menteri Sosial No 1 Tahun 2019, bantuan sosial merupakan bantuan berupa uang, barang, atau jasa kepada seseorang, keluarga, kelompok, atau masyarakat miskin yang tidak mampu atau rentan terhadap resiko sosial. Dalam intervensi masalah kemiskinan maka dibangun sebuah inovasi yaitu program Bantuan Pangan Non Tunai (BPNT). Masalah penerima bantuan pangan non tunai kadang kala tidak tepat sasaran karena proses seleksi dan pendataan masih dilakukan secara tradisional. Dalam banyak kasus, proses manual rentan terhadap human error, keterbatasan data, dan bias subjektif. Oleh karena itu penggunaan analisis klasifikasi dapat membantu mengatasi masalah ini. Algoritma Support Vector Machine (SVM) patut dipertimbangkan karena memiliki keakuratan dan efisiensi dalam hal klasifikasi. Penelitian ini bertujuan untuk menggali lebih jauh potensi penggunaan algoritma SVM terkait identifikasi status penerima bantuan sosial. Hasil analisis klasifikasi pada studi kasus status penerima bantuan pangan non tunai dengan metode support vector machine (SVM) menghasilkan performa model yang bervariasi. Pengujian algoritma dilakukan dengan teknik k-fold cross validation melibatkan empat jenis kernel, yaitu kernel linear, kernel polinomial, kernel fungsi basis radial, dan kernel sigmoid. Rata-rata akurasi berturut-turut adalah kernel linier (98,1%), kernel fungsi basis radial (98,1%), kernel sigmoid (95,4%), dan kernel polinomial (88,0%). Dengan demikian algoritma SVM kernel linier dan kernel fungsi radial basis merupakan algoritma dan teknik terbaik untuk mengidentifikasi masyarakat dalam memperoleh bantuan pangan non tunai.*

### Abstract

*In Minister of Social Affairs Regulation No. 1 of 2019, social assistance is assistance in the form of money, goods, or services to a person, family, group, or poor community who are unable or vulnerable to social risks. To intervene in the problem of poverty, an innovation was built, namely the Non-Cash Food Assistance (NCFA) program. The problem is that recipients of non-cash food aid are sometimes not well targeted because the selection and data collection process is still carried out traditionally. In many cases, manual processes are susceptible to human error, data limitations, and subjective bias. Therefore the use of classification analysis can help overcome this problem. The Support Vector Machine (SVM) algorithm is worth considering because it has accuracy and efficiency in terms of classification. This research aims to further explore the potential for using the SVM algorithm regarding identifying the status of social assistance recipients. The results of classification analysis in case studies of non-cash food aid recipient status using the support vector machine (SVM) method produce varying model performance. Algorithm testing was carried out using the k-fold cross validation technique involving four types of kernels, namely linear kernels, polynomial kernels, radial basis function kernels, and sigmoid kernels. The average accuracies were linear kernel (98.1%), radial basis function kernel (98.1%), sigmoid kernel (95.4%), and polynomial kernel (88.0%). Thus, the linear kernel SVM algorithm and radial basis function kernel are the best algorithms and techniques for identifying people who receive non-cash food assistance.*

**Keywords:** *assistance, classification, linear kernel, radial basis function, SVM*

## 1. PENDAHULUAN

Dalam Peraturan Menteri Sosial No 1 Tahun 2019, bantuan sosial merupakan bantuan berupa uang, barang, atau jasa kepada seseorang, keluarga, kelompok, atau masyarakat miskin yang tidak mampu atau rentan terhadap resiko sosial. Dalam intervensi masalah kemiskinan maka dibangun sebuah inovasi yaitu program Bantuan Pangan Non Tunai (BPNT). BPNT merupakan program bantuan sosial pangan dalam bentuk non tunai untuk Keluarga Penerima Manfaat yang diberikan setiap bulannya oleh pemerintah melalui mekanisme akun elektronik yang digunakan untuk membeli bahan pangan ke pedagang yang bekerja sama dengan bank [1].

Masalah penerima bantuan sosial kadang kala tidak tepat sasaran karena proses seleksi dan pendataan masih dilakukan secara tradisional. Dalam banyak kasus, proses manual rentan terhadap *human error*, keterbatasan data, dan bias subjektif. Oleh karena itu penggunaan analisis klasifikasi dapat membantu mengatasi masalah ini, dengan cara mengotomatisasi proses seleksi dan identifikasi ketepatan kepada penerima bantuan yang benar-benar membutuhkan.

Beberapa penelitian terkait fenomena seperti ini telah dilakukan secara luas. Penelitian oleh Pratama [2] yang menggunakan metode Naive Bayes untuk mengklasifikasikan kriteria penerima bantuan pangan non tunai. Tujuan penelitian tersebut untuk mempermudah petugas dalam mengklasifikasikan bantuan agar tepat sasaran sehingga kegiatan dapat berjalan secara optimal. Akurasi yang diperoleh sebesar 96,36% yang menunjukkan hasil yang sangat baik. Penelitian oleh Qamariah *et al.* [3] menerapkan metode *Decision Tree* dan Adaboost dalam menentukan penerima program bantuan sosial. Hasil penelitian diperoleh metode *Decision Tree* dan Adaboost menghasilkan akurasi yang sangat baik, yaitu 94,17% dan 95%, sehingga kedua metode tersebut sangat cocok digunakan dalam analisis kasus tersebut. Penelitian oleh Muti dan Pamuji [4] dalam membandingkan metode Naive Bayes dan *K-Nearest Neighbors* (KNN) pada klasifikasi kelayakan keluarga terdaftar Data Terpadu Kesejahteraan Sosial (DTKS). Hasil analisis ditemukan akurasi Naive Bayes sebesar 82% lebih baik dibandingkan dengan KNN sebesar 70%. Penelitian oleh Badrial *et al.* [5] yang menggunakan algoritma C4.5 dalam menentukan status penerima bantuan Covid-19. Hasil penelitian diperoleh akurasi sebesar 79,54% untuk proporsi 90% data *training* dan 10% data *testing*.

Selain algoritma klasifikasi yang telah dijelaskan sebelumnya. Algoritma *Support Vector Machine* (SVM) patut dipertimbangkan karena memiliki keakuratan dan efisiensi dalam hal klasifikasi. Algoritma SVM telah terbukti mampu secara efektif dalam pengenalan pola, terutama pada kinerja klasifikasi data pada kumpulan data berdimensi tinggi [6]. Jika dibandingkan dengan algoritma klasifikasi lainnya, SVM memiliki keunggulan yang telah diakui sebagai pendekatan kompetitif [6]. Kemampuannya secara efektif dalam menangani kumpulan data *training* dalam jumlah kecil. Selain itu, keunggulan yang membedakan dengan pengklasifikasi lainnya adalah intensitas komputasi yang lebih rendah dan kinerja yang kuat dalam ruang berdimensi tinggi. SVM dengan kernel fungsi basis radial dipilih sebagai metode klasifikasi karena beberapa alasan: (1) SVM adalah pengklasifikasi yang lazim digunakan dalam analisis penginderaan jarak jauh. (2) SVM adalah pengklasifikasi nonparametrik, yang berarti tidak membuat asumsi mengenai distribusi data yang mendasarinya. Ini mungkin menguntungkan untuk set sampel kecil. (3) SVM dapat bekerja dengan baik dengan data

*training* yang relatif kecil jika dibandingkan dengan pengklasifikasi lain yang umum digunakan. (4) SVM menarik karena kemampuannya untuk menemukan keseimbangan antara akurasi dan generalisasi [7].

Berdasarkan paparan yang telah dijelaskan. Penelitian ini bertujuan untuk menggali lebih jauh potensi penggunaan algoritma SVM terkait identifikasi status penerima bantuan sosial. Data yang digunakan diperoleh dari penelitian Pratama [2]. Diharapkan penelitian dapat menjadi solusi potensial dalam menangani masalah klasifikasi penerima bantuan sosial agar lebih akurat dan tepat sasaran sehingga memberikan dampak positif yang lebih besar di masyarakat.

## 2. METODOLOGI PENELITIAN

### 2.1 Jenis dan Sumber Data

Data dalam penelitian merupakan data sekunder yang diperoleh dari penelitian Pratama [2]. Metode pengumpulan data melalui wawancara, catatan arsip penerima bantuan pangan, dan riset internet. Beberapa variabel yang digunakan dalam analisis ini disajikan dalam Tabel 1.

Tabel 1. Variabel dan Tipe Data

Variabel	Tipe Data
Penerima Bantuan Pangan	Kategorik: Layak atau Tidak Layak
Pendidikan Kepala Keluarga	Kategorik: SD, SMP, SMA, D3, S1, atau S2
Pekerjaan Kepala Keluarga	Kategorik: Buruh, Pedagang, Petani, PNS, Tidak Bekerja, atau Wirausaha
Penghasilan Kepala Keluarga	Numerik
Jumlah Anggota Keluarga	Numerik
Kondisi Rumah	Kategorik: Permanen atau Semi Permanen
Alat Transportasi	Kategorik: Mobil, Motor, atau Tidak Keduanya
Kondisi Lantai Rumah	Kategorik: Keramik, Semen, atau Tanah

### 2.2 Support Vector Machine (SVM)

Model SVM memberikan visualisasi umum dalam memisahkan amatan dari pembuatan *hyperplane* yang memaksimalkan jarak antara margin atas dan bawah yang dibangun oleh data *training*. Model SVM yang paling sederhana dan paling dasar adalah SVM linear. Model ini berupaya mengklasifikasikan data yang dapat dipisahkan secara linear dengan menggambar garis lurus antarkelompok. Selain itu memiliki margin yang kaku (mengklasifikasikan model untuk menghindari kesalahan klasifikasi tetapi dapat membuat sulit menggeneralisasi) atau margin yang fleksibel (memasukkan variabel slack yang memungkinkan terjadi beberapa kesalahan klasifikasi tetapi mendukung generalisasi model) [8].

Diberikan kumpulan data *training* pada ruang fitur tertentu [9].

$$D = (x_1, y_1), (x_2, y_2), \dots, (x_n, y_n) \quad (1)$$

dengan  $x_i \in R^d$ ;  $y_i \in \{+1, -1\}$ ;  $i = 1, 2, \dots, n$ ;  $x_i$  merupakan vektor eigen ke- $i$ ,  $y_i$  merupakan label kelas yang merepresentasikan positif untuk +1 dan negatif untuk -1,  $n$  adalah jumlah data *training*, dan  $d$  adalah jumlah variabel independen.

Dalam ruang sampel, *hyperplane* bertanggungjawab dalam memisahkan amatan dan dapat diwakili oleh persamaan linear berikut.

$$\omega \cdot x + b = 0 \quad (2)$$

dengan  $b$  merupakan suku perpindahan,  $\omega = (\omega_1, \omega_2 \dots, \omega_d)$  adalah vektor normal yang menentukan arah *hyperplane*. Jarak titik  $x$  dalam ruang sampel *hyperplane* dapat ditulis sebagai berikut.

$$\gamma = \frac{|\omega^T x + b|}{\|\omega\|} \quad (3)$$

Asumsikan *hyperplane*  $(\omega, b)$  dapat diklasifikasikan sebagai sampel training yang terklasifikasi benar. Kemudian untuk  $(x_i, y_i) \in D$  jika  $y_i = +1$  maka  $\omega^T x + b > 0$ ; jika  $y_i = -1$  maka  $\omega^T x + b < 0$  [9]. Oleh karena itu,

$$\begin{aligned} \omega^T x_i + b &> +1; y = +1 \\ \omega^T x_i + b &< -1; y = -1 \end{aligned} \quad (4)$$

Sampel yang memvalidasi persamaan diatas adalah “*support vector*” yang paling dekat dengan *hyperplane*, dan jumlah jarak dari dua *support vector* heterogen ke *hyperplane* sebagai berikut.

$$\gamma = \frac{2}{\|\omega\|} \quad (5)$$

Dalam mencari *hyperplane* dengan interval maksimum maka  $\gamma$  harus maksimum. Oleh karena itu cukup memaksimalkan  $\|\omega\|^{-1}$  yang setara dengan meminimalkan  $\|\omega\|^2$ . Dalam hal ini perlu ditentukan parameter  $\omega$  dan  $b$  yang memenuhi persamaan berikut.

$$\frac{1}{2} \|\omega\|^2 \quad (6)$$

dengan batasannya sebagai berikut.

$$y_i(\omega \cdot x_i + b) - 1 \geq 0, i = 1, 2, \dots, n \quad (7)$$

Masalah optimasi dapat diatasi dengan metode Lagrange.

$$L(\omega, b, \alpha) = \frac{1}{2} \|\omega\|^2 - \sum_{i=1}^m \alpha_i (y_i(\omega x_i + b) - 1) \quad (8)$$

dengan  $\alpha_i$  merupakan pengali Lagrange untuk setiap sampel dan turunan dari  $L$  terhadap  $\omega$  dan  $b$  masing-masing sama dengan nol.

$$\sum_{i=1}^m \alpha_i y_i = 0 \quad (9)$$

$$\omega = \sum_{i=1}^m \alpha_i y_i x_i = 0 \quad (10)$$

Oleh karena itu, vektor solusi mempunyai perluasan yang terdiri dari subset dari kumpulan sampel pelatihan yang pengali Lagrange tidak nol, yaitu *support vector*. Fungsi keputusan yang menggambarkan *hyperplane* klasifikasi optimal yang diperoleh dalam set pelatihan disebut *support vector machine*, yang fungsi klasifikasinya ditentukan oleh *support vector*. Fungsi keputusan dapat dinyatakan sebagai berikut.

$$f(x) = \text{sgn}(\sum_{i=1}^m \alpha_i y_i (x \cdot x_i) + b) \quad (11)$$

Untuk kondisi yang tidak dapat dipisahkan secara linear,  $\xi_i \geq 0$ , dapat ditambahkan pada persamaan (7).

$$(y_i(\omega \cdot x_i + b) - 1) + \xi_i \geq 0, i = 1, 2, \dots, n \quad (12)$$

Sehingga,

$$L(\omega, b, \alpha, \xi_i) = \frac{1}{2} \|\omega\|^2 - \sum_{i=1}^m \alpha_i ((y_i(\omega x_i + b) - 1) + \xi_i) \quad (13)$$

Fungsi keputusan ( $x \cdot x_i$ ) sebenarnya ekuivalen dengan kemiripan  $x$  dan  $x_i$ . Dalam kebanyakan kasus, fungsi kernel diperlukan untuk dua vektor sampel  $x$  dan  $x_i$ . Nilai balik menggambarkan kesamaan antara dua vektor. Untuk situasi yang tidak dapat dipisahkan secara linier, sampel yang akan diklasifikasikan dapat dipetakan ke ruang fitur berdimensi tinggi dengan memilih transformasi non linear yang sesuai, sehingga sampel tersebut dapat dipisahkan secara linier. Jika fungsi non linier dinyatakan dalam  $\phi(x)$ , maka fungsi keputusan *hyperplane* dapat dituliskan sebagai berikut.

$$f(x) = \text{sgn}(\sum_{i=1}^m \alpha_i y_i (\phi(x) \cdot \phi(x_i)) + b) \quad (14)$$

Fungsi kernel umum mencakup fungsi linier, fungsi polinomial, fungsi Gaussian/ fungsi basis radial, dan fungsi sigmoid yang dinyatakan pada Tabel 2.

Tabel 2. Formula Kernel

Fungsi Kernel	Formula
Linear	$K(x_i, x_j) = x_i \cdot x_j$
Polinomial	$K(x_i, x_j) = (x_i \cdot x_j)^d$
Gaussian/ Fungsi Basis Radial	$K(x_i, x_j) = \exp\left(-\frac{ x_i - x_j ^2}{2\sigma^2}\right)$
Sigmoid	$K(x_i, x_j) = \tanh(\sigma(x_i \cdot x_j) + c)$

### 2.3 K-Fold Cross Validation

Teknik *k-fold cross validation* merupakan teknik yang pemisahan data menjadi  $k$  subhimpunan yang berbeda, lalu dilakukan proses uji sebanyak  $k$  kali [10]. Tujuan penggunaan teknik ini untuk meninjau konsistensi performa model yang tidak hanya mampu bekerja pada data *training* tetapi juga pada data *testing*. Misalkan, jika nilai  $k = 10$  ditetapkan, kumpulan data akan dibagi menjadi 10 partisi. Dalam hal ini, 9 partisi digunakan untuk data pelatihan, sedangkan 1 partisi sisanya digunakan untuk data pengujian. Pelatihan diulang 10 kali, setiap kali menggunakan partisi berbeda sebagai set pengujian dan 9 partisi sisanya sebagai data pelatihan. Kemudian dihitung rata-rata akurasinya.

### 2.4 Uji Performa Model

Suatu model dapat diketahui tingkat keberhasilannya dengan melihat seberapa jauh model dapat memutuskan data yang masuk pada kelas yang tepat. Untuk mengetahui hal tersebut maka hasil klasifikasi dapat disusun dalam sebuah tabel yang disebut *confusion matrix* [11][12][13].

Table 3. *Confusion Matrix*

		Kelas Prediksi	
		Positif	Negatif
Kelas Observasi	Positif	<i>a</i>	<i>b</i>
	Negatif	<i>c</i>	<i>d</i>

Tingkat keberhasilan diformulasikan sebagai berikut [14][15].

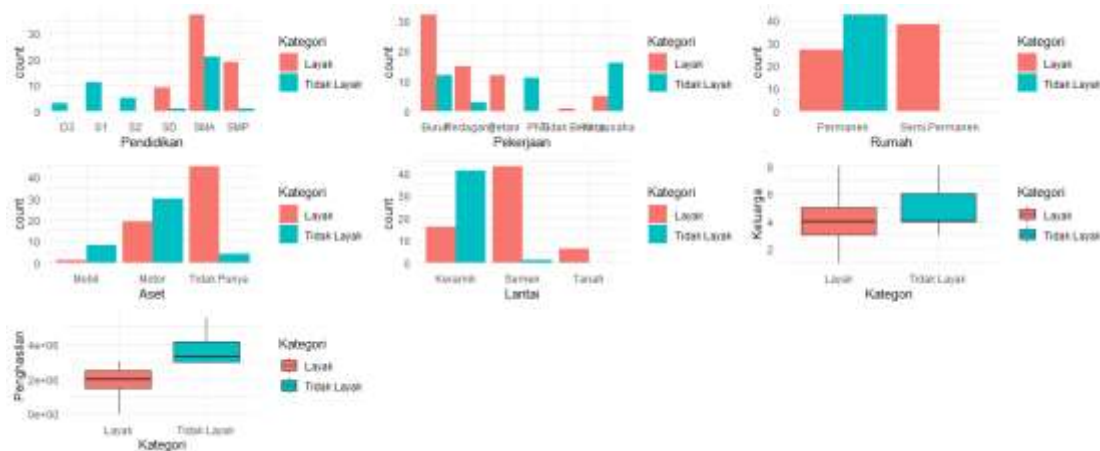
$$Akurasi = \frac{a+d}{a+b+c+d} \quad (15)$$

Dengan *a* menyatakan terklasifikasi benar sebagai kelas positif, *b* menyatakan terklasifikasi salah sebagai kelas negatif, *c* menyatakan terklasifikasi salah sebagai kelas positif, dan *d* menyatakan terklasifikasi benar sebagai kelas negatif [16].

### 3. HASIL DAN ANALISIS

#### 3.1 Eksplorasi Data

Eksplorasi data dijalankan dengan merancang grafik variabel independen yang dikaitkan dengan variabel dependen seperti pada Gambar 1. Pada grafik pertama menampilkan grafik batang pendidikan terhadap status penerima bantuan pangan, yaitu layak dan tidak layak. Kepala keluarga dengan pendidikan terakhir SMA layak menerima bantuan pangan sebanyak 37 orang sedangkan 21 orang dengan tingkat pendidikan serupa tidak layak menerima bantuan pangan. Grafik kedua menunjukkan 32 kepala keluarga dengan pekerjaan buruh layak menerima bantuan pangan. Sedangkan 16 kepala keluarga dengan pekerjaan sebagai wirausaha tidak layak menerima bantuan pangan. Grafik ketiga menyajikan sebanyak 38 kepala keluarga yang tinggal dengan kondisi rumah semi permanen layak menerima bantuan pangan dibandingkan 42 kepala keluarga yang tinggal dengan kondisi rumah permanen. Grafik keempat mempresentasikan aset transportasi kepala keluarga. Sebanyak 45 kepala keluarga yang tidak memiliki alat transportasi layak menerima bantuan pangan sedangkan 30 kepala keluarga yang memiliki sepeda motor tidak layak menerima bantuan pangan. Grafik kelima memperlihatkan 43 kepala keluarga yang menempati rumah dengan kondisi lantai semen layak menerima bantuan pangan. Sementara itu, 41 kepala keluarga yang tinggal di rumah dengan lantai keramik tidak layak menerima bantuan pangan.

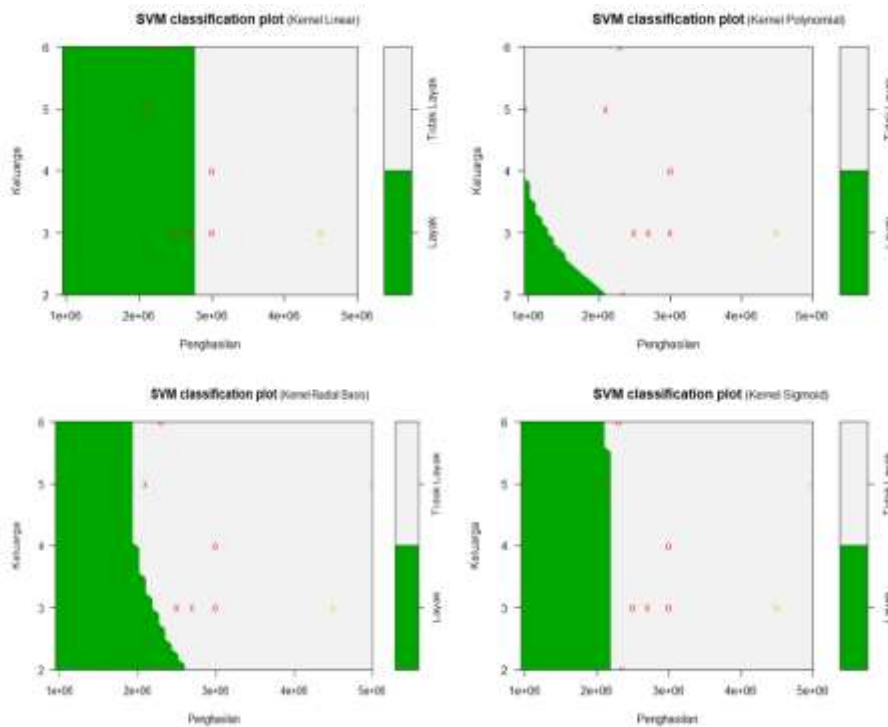


Gambar 1. Variabel Independen Terhadap Variabel Dependen

Grafik keenam menampilkan grafik boxplot jumlah anggota keluarga yang dimiliki kepala keluarga terhadap status penerima bantuan pangan. Rata-rata mereka yang memiliki 3 anggota keluarga dalam rumahnya layak menerima bantuan pangan. Sementara itu, kepala keluarga yang memiliki 4 anggota keluarga tidak layak menerima bantuan pangan. Grafik ketujuh menyajikan grafik pendapatan dari kepala keluarga terhadap status penerima bantuan pangan. Kepala keluarga yang memperoleh penghasilan pada rentang 0 hingga 3 juta rupiah layak menerima bantuan pangan sedangkan penghasilan kepala keluarga lebih dari 3 juta rupiah tidak layak menerima bantuan pangan.

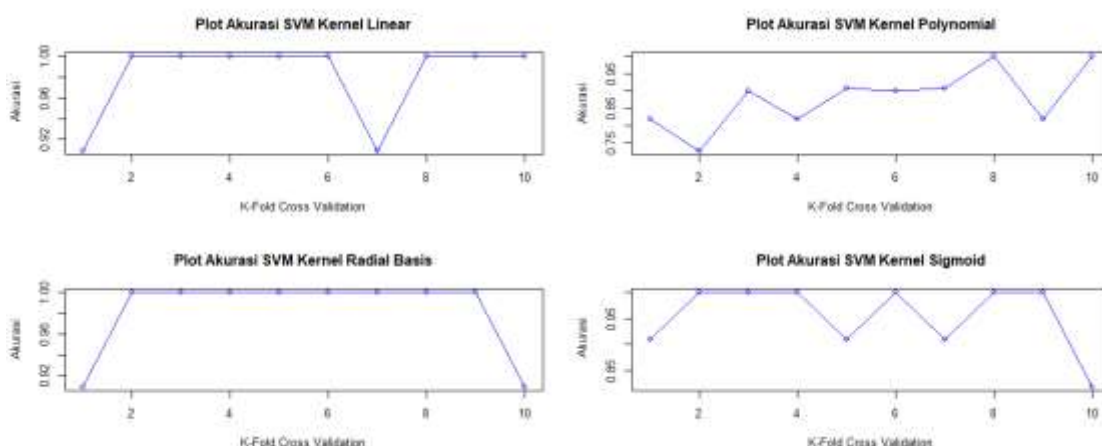
### 3.2 Kinerja Model *Support Vector Machine* (SVM)

Pada Gambar 2 menampilkan visualisasi kualitas model SVM pada fungsi kernel yang berbeda. Fungsi kernel yang digunakan adalah kernel linear, kernel polinomial, kernel fungsi basis radial, dan kernel sigmoid. Setiap fungsi kernel memisahkan dua kelas (layak dan tidak layak) berdasarkan dua variabel, yaitu jumlah keluarga dan penghasilan kepala keluarga. Plot pertama merupakan visualisasi hasil uji dengan data *testing* menggunakan metode SVM kernel linear. Garis pemisah yang membagi area abu-abu dan hijau merupakan *hyperplane* dari fungsi kernel linear. Total yang terprediksi benar pada kelas layak sebanyak 9 amatan sedangkan yang terprediksi benar pada kelas tidak layak sebanyak 2 amatan. Akurasi yang dihasilkan adalah 100%. Plot kedua merupakan hasil uji dengan fungsi kernel polinomial. Total yang terprediksi tepat pada kedua kelas sebanyak 10 amatan sedangkan 1 amatan lainnya terprediksi tidak tepat. Akurasi yang dihasilkan adalah 90,9%. Plot ketiga dan plot keempat merupakan hasil uji melibatkan fungsi kernel fungsi basis radial dan kernel sigmoid. Hasil performa senada dengan fungsi kernel linear dengan akurasi yang diperoleh adalah 100%.



Gambar 2. *Hyperplane Model SVM*

Dalam mengetahui kinerja model SVM maka digunakan metode *k-fold cross validation*. Tujuannya adalah mengukur kestabilan performa model dalam memprediksi data pada masing-masing lipatan. Jumlah lipatan yang digunakan sebanyak 10 lipatan. Setiap lipatan terdiri dari 9 kelompok sebagai data *training* dan 1 kelompok menjadi data *testing*. Akurasi model SVM pada setiap fungsi kernel ditampilkan pada Gambar 3.



Gambar 3. *K-Fold Cross Validation dari Kernel SVM*

Plot pertama memperlihatkan akurasi model SVM kernel linear untuk setiap lipatan. Model SVM kernel linear memiliki performa sangat baik dan stabil pada sebagian



besar lipatan. Akurasi berkisar antara 0,909 (90,9%) hingga 1 (100%) dan rata-rata yang dihasilkan adalah 0,981 (98,1%). Plot kedua menunjukkan akurasi model SVM kernel polinomial. Terdapat variasi yang signifikan pada setiap lipatannya sehingga membuat performa model cenderung tidak stabil. Akurasi berkisar antara 0,727 (72,7%) hingga 1 (100%) dan rata-rata dari setiap lipatan adalah 0,88 (88,0%). Plot ketiga menyajikan akurasi model SVM kernel fungsi basis radial. Model SVM kernel fungsi basis radial memiliki rata-rata akurasi yang serupa dengan kernel linier. Terakhir, plot akurasi model SVM kernel sigmoid. Akurasi setiap lipatan berkisar antara 0,818 (81,8%) hingga 1 (100%) dan menghasilkan rata-rata akurasi sebesar 0,954 (95,4%). Jadi model SVM terbaik secara berturut-turut yaitu SVM kernel linear, SVM kernel fungsi basis radial, SVM kernel sigmoid, dan SVM kernel polinomial.

Penelitian sebelumnya yang dilakukan oleh Pratama [2], variabel jumlah anggota keluarga dan penghasilan kepala keluarga diubah dari skala numerik menjadi kategorik. Selain itu peneliti tidak memasukkan variabel pendidikan. Analisis yang diterapkan menggunakan metode Naive Bayes. Jumlah data *training* sebanyak 84 amatan sedangkan 23 amatan lainnya sebagai data *testing*.

Pengujian selanjutnya dilakukan dengan metode SVM mengikuti proporsi data berdasarkan penelitian terdahulu. Selain itu, variabel jumlah anggota keluarga dan penghasilan kepala keluarga tetap dalam skala numerik serta melibatkan variabel pendidikan dalam analisis ini. Hasil uji disajikan pada Tabel 4.

Tabel 4. Akurasi Kinerja Model Klasifikasi

Metode	Akurasi
Naive Bayes	0,964
SVM Kernel Linear	0,988
SVM Kernel Polinomial	0,833
SVM Kernel Fungsi Basis Radial	0,988
SVM Kernel Sigmoid	0,976

Penelitian dari Pratama [2] dengan algoritma Naive Bayes menghasilkan akurasi yang baik sebesar 0,964 (96,4%), namun akurasi tersebut tidak sebesar beberapa algoritma SVM lainnya. Performa model SVM kernel linear dan kernel fungsi basis radial sama-sama memberikan akurasi tertinggi dibandingkan metode lainnya, yaitu 0,988 (98,8%). Model SVM kernel sigmoid memberikan akurasi sebesar 0,976 (97,6%), sedikit lebih rendah dibandingkan model SVM kernel linear dan kernel fungsi basis radial. Model SVM kernel polinomial memberikan akurasi paling rendah dibandingkan model lainnya, yaitu 0,833 (83,3%). Hal ini dapat disebabkan *hyperplane* yang dibentuk oleh fungsi kernel polinomial tidak dapat menangkap pola data dengan baik sehingga mempengaruhi kinerja kernel ini.

Hasil penelitian menunjukkan pemilihan tipe kernel memainkan peran penting pada peningkatan akurasi klasifikasi. Setiap kernel memiliki dampak yang berbeda dalam mengenali pola sebuah data. Seperti penelitian yang dilakukan oleh Ustuner *et al.* [17] dalam mengaplikasikan metode SVM untuk klasifikasi penggunaan lahan. Terdapat empat jenis kernel yang digunakan dalam analisis tersebut, yaitu kernel linear,

polinomial, fungsi basis radial, dan sigmoid. Model SVM kernel polinomial terbaik mengungguli semua model SVM dan memberikan akurasi klasifikasi tertinggi sebesar 85,63%. Akurasi klasifikasi model terbaik untuk setiap tipe kernel masing-masing adalah 85,63%; 83,94%; 83,94%; 83,82%; dan 81,64% untuk kernel polinomial, linier, fungsi basis radial, dan sigmoid. Penelitian lainnya oleh Sonmez *et al.* [18] yang mengklasifikasikan mikroalga di ekosistem laut melalui jaringan syaraf konvolusional dan SVM. Dalam klasifikasi dataset yang terdiri dari 7820 gambar menggunakan empat fungsi kernel SVM yang berbeda, kernel linier mencapai tingkat keberhasilan tertinggi sebesar 98,79%. Hal ini diikuti oleh kernel fungsi basis radial sebesar 98,73%, kernel polinomial sebesar 97,84%, dan kernel sigmoid sebesar 97,20%.

#### 4. KESIMPULAN

Berdasarkan hasil dan pembahasan maka dapat ditarik beberapa kesimpulan. Hasil analisis klasifikasi pada studi kasus status penerima bantuan pangan dengan metode *support vector machine* (SVM) menghasilkan performa model yang bervariasi. Pengujian algoritma dilakukan dengan teknik *k-fold cross validation* melibatkan empat jenis kernel, yaitu kernel linear, kernel polinomial, kernel fungsi basis radial, dan kernel sigmoid. Rata-rata akurasi terbaik berturut-turut adalah kernel linier (98,1%), kernel fungsi basis radial (98,1%), kernel sigmoid (95,4%), dan kernel polinomial (88,0%). Hal ini menunjukkan bahwa model SVM pada kernel linier dan kernel fungsi basis radial dapat menangkap pola data dengan sangat baik dibandingkan dengan kernel polinomial.

Hasil penelitian senada ditunjukkan saat membandingkan penelitian terdahulu yang dilakukan dengan metode Naive Bayes. Ketepatan klasifikasi yang dihasilkan dengan metode SVM kernel linear dan kernel fungsi basis radial mendekati sempurna, yaitu 98,8%. Performa model ini lebih baik dibandingkan dengan metode Naive Bayes yang memberikan akurasi sebesar 96,4%. Namun, kinerja model Naive Bayes masih jauh lebih baik daripada model SVM kernel polinomial yang akurasinya adalah 83,3%.

Pada penelitian selanjutnya disarankan dapat mengembangkan metode SVM dengan variasi kernel yang lain untuk melihat seberapa baik performa modelnya. Selain itu, dapat digunakan algoritma klasifikasi yang lain seperti regresi logistik, *decision tree*, *k-nearest neighbor*, dll. dalam meningkatkan kinerja model klasifikasi.

#### DAFTAR PUSTAKA

- [1] A. A. Kurniawan, "Efektivitas Program Bantuan Pangan Non Tunai (BPNT) Di Kecamatan Kanigaran Kota Probolinggo," Doctoral dissertation, Universitas 17 Agustus 1945, 2020.
- [2] M. Z. Pratama, "Penentuan Kriteria Dan Penerima Bantuan Pangan Non Tunai Di Desa Parungkuda Dengan Menggunakan Algoritma Naïve Bayes," Skripsi, Universitas Bina Sarana Informatika, Sukabumi, 2020.
- [3] M. Qamariah, A. Afifuddin, and S. Suyeno, "Implementasi Program Bantuan Sosial Dalam Pemenuhan Kebutuhan Lansia Terlantar (Studi Pada Dinas Sosial Kota Batu)," Respon Publik, vol. 14, no. 4, pp. 1-7, 2020.
- [4] D. Muti and F. Y. Pamuji, "Analisis Perbandingan Metode Naïve Bayes dan K-NN dalam Klasifikasi Kelayakan Keluarga Terdaftar DTKS Penerimaan Bantuan Sosial

- di Desa Dubesi," in Seminar Nasional Sistem Informasi (SENASIF), vol. 7, pp. 3753-3761, Sep. 2023.
- [5] S. Badriah, M. F. E. Nugroho, N. Sanjaya, I. Rismawati, B. N. Sari, and C. Rozikin, "Klasifikasi Algoritma C4.5 dalam Menentukan Penerima Bantuan Covid-19: (Studi Kasus: Desa di Karawang)," *Jurnal Informatika Polinema*, vol. 7, no. 3, pp. 23-28, 2021.
- [6] S. A. Salleh, N. Khalid, N. Danny, N. A. M. Zaki, M. Ustuner, Z. Abd Latif, and V. Foronda, "Support Vector Machine (SVM) and Object Based Classification in Earth Linear Features Extraction: A Comparison," *Revue Internationale de Géomatique*, vol. 33, no. 1, pp. 183–199, 2024, doi: 10.32604/riq.2024.050723.
- [7] C. A. Ramezan, T. A. Warner, and A. E. Maxwell, "Evaluation of Sampling and Cross-Validation Tuning Strategies for Regional-Scale Machine Learning Classification," *Remote Sensing*, vol. 11, no. 2, p. 185, Jan. 2019, doi: 10.3390/rs11020185.
- [8] J. S. Pimentel, R. Ospina, and A. Ara, "A novel fusion Support Vector Machine integrating weak and sphere models for classification challenges with massive data," *Decision Analytics Journal*, vol. 11, p. 100457, Jun. 2024, doi: 10.1016/j.dajour.2024.100457.
- [9] J. Cai and N. Xi, "Site classification methodology using support vector machine: A study," *Earthquake Research Advances*, p. 100294, Mar. 2024, doi: 10.1016/j.eqrea.2024.100294.
- [10] A. Aprihartha, "Penyelesaian Masalah Ketidakseimbangan Data Melalui Teknik Oversampling dan Undersampling pada Klasifikasi Siswa Tidak Naik Kelas," *Jurnal Teknik Ibnu Sina (JT-IBSI)*, vol. 9, no. 01, pp. 43-52, 2024.
- [11] M. A. Aprihartha, J. Prasetya, and S. I. Fallo, "Implementasi CART-Real Adaboost dalam Memprediksi Minat Pelanggan Membeli Sepatu," *Jurnal EurekaMatika*, vol. 12, no. 1, pp. 35-46, 2024.
- [15] J. Prasetya, S. I. Fallo, and M. A. Aprihartha, "Stacking Machine Learning Model for Predict Hotel Booking Cancellations," *Jurnal Matematika, Statistika dan Komputasi*, vol. 20, no. 3, pp. 525–537, May 2024, doi: 10.20956/j.v20i3.32619.
- [13] M. A. Aprihartha, F. Astutik, and N. Sulistianingsih, "Comparison of Naïve Bayes, CART, dan CART Adaboost Methods in Predicting Tire Product Sales," *Jurnal Matematika, Statistika dan Komputasi*, vol. 20, no. 3, pp. 596–605, May 2024, doi: 10.20956/j.v20i3.33187.
- [14] A. Aprihartha, Z. Putrawan, D. Zulhan, and F. A. Nurfaizal, "Klasifikasi Produktivitas Buah Nanas Menggunakan Algoritma Classification and Regression Tree (CART)," *Diophantine Journal of Mathematics and Its Applications*, pp. 64-70, 2024.
- [15] M. A. Aprihartha, T. N. Alam, and M. Husniyadi, "Perbandingan Metrik Euclidean dan Metrik Manhattan untuk K-Nearest Neighbors dalam Klasifikasi Kismis," *Jurnal Ilmu Komputer dan Informatika*, vol. 4, no. 1, pp. 21-30, 2024.
- [16] M. A. Aprihartha, Z. Putrawan, D. Zulhan, and F. A. Nurfaizal, "Algoritma Synthetic Minority Oversampling Technique dan C5.0 dalam Mengatasi Ketidakseimbangan Data pada Klasifikasi Kelulusan Siswa," *UPGRADE: Jurnal Pendidikan Teknologi Informasi*, vol. 2, no. 1, pp. 1-10, 2024.

- [17] M. Ustuner, F. B. Sanli, and B. Dixon, "Application of Support Vector Machines for Landuse Classification Using High-Resolution RapidEye Images: A Sensitivity Analysis," *European Journal of Remote Sensing*, vol. 48, no. 1, pp. 403–422, Jan. 2015, doi: 10.5721/EuJRS20154823.
- [18] M. E. Sonmez, N. E. Gumus, N. Eczacioglu, E. E. Develi, K. Yücel, and H. B. Yildiz, "Enhancing microalgae classification accuracy in marine ecosystems through convolutional neural networks and support vector machines," *Marine Pollution Bulletin*, vol. 205, p. 116616, Aug. 2024, doi: 10.1016/j.marpolbul.2024.116616.