

PERFORMANSI *PIECEWISE POLYNOMIAL SMOOTH SUPPORT VECTOR MACHINE* UNTUK KLASIFIKASI DESA TERTINGGAL DI PROVINSI KALIMANTAN TIMUR TAHUN 2011

Ita Wulandari

Dosen Sekolah Tinggi Ilmu Statistik

Abstract

One of most popular techniques of binary data classification in machine learning is Support Vector Machine (SVM). SVM can be applied extensively in many fields, such as pattern recognition, regression analysis, and probability estimation. SVM uses optimization with quadratic programming which become unefficient when applied in a high dimensional large dataset. Hence, researchers develop a method by changing SVM formulation with a smoothing technique that called Smooth-SVM (SSVM) which converts quadratic into linear programming. The research then continued by modifying that smooth function into polynomial smooth function forms, such as quadratic polynomial function, fourth polynomial function, piecewise polynomial function and spline function. Compared to the other polynomial smooth functions, piecewise polynomial smooth function has a better performance in plus function. When piecewise polynomial smooth function is applied in SSVM model, it will produce piecewise polynomial smooth support vector machine (PPSSVM). PPSSVM has many advantages compared to other SSVM models and its developments such as better efficiency, precision and higher accuracy in generalization. Two PPSSVM model based on piecewise polynomial function are used in this research which found by Luo (PPSSVM1) and Wu and Wang (PPSSVM2). The performance and the convergence of both models then will be examined theoretically, in order to determine the best model for classification of underdeveloped rural in East Kalimantan. PODES data in 2011 will be used in this research. Teoritical analysis showed that PPSSVM2 has a better performance and konvergence than PPSSVM1. Based on the result of this study, PPSSVM2 is not batter than PPSSVM1. It can be seen from the accuracy and AUC values that are not significantly different.

Key words: *underdeveloped rural, piecewise polynomial smooth function, SVM, smooth SVM.*

I. PENDAHULUAN

Klasifikasi merupakan pengelompokan obyek ke dalam satu atau beberapa kelompok berdasarkan variabel yang diamati. Metode klasifikasi dapat dilakukan dengan pendekatan parametrik dan pendekatan nonparametrik. Dalam pendekatan parametrik terdapat beberapa metode klasifikasi yang sering digunakan antara lain: Analisis Regresi Logistik, Analisis Diskriminan dan Analisis Regresi Probit. Regresi logistik dan regresi probit memiliki kelemahan, yaitu nilai yang dihasilkan model regresi logistik dan probit berupa nilai probabilitas yang dirasa kurang praktis (Yohannes and Webb, 1999). Pada analisis diskriminan, data diharuskan memenuhi beberapa asumsi yaitu data harus berdistribusi normal multivariat dan matrik kovarian yang sama untuk setiap populasi (Breiman, Friedman, Olshen, and Stone, 1984).

Dengan adanya keterbatasan metode klasifikasi parametrik, maka digunakan pendekatan nonparametrik. Pendekatan tersebut tidak bergantung pada asumsi tertentu sehingga memberikan fleksibilitas yang lebih besar dalam menganalisa data tetapi tetap mempunyai tingkat akurasi yang tinggi dan mudah dalam penggunaannya. Beberapa teknik pemodelan berbasis *machine learning* dikembangkan untuk membantu klasifikasi melalui metode nonparametrik, seperti *Multivariate Adaptive Regression Spline* (MARS) dan *Feed-Forward Neural Network* (FFNN), *k-Nearest Neighbors* (k-NN), *Classification Adaptive Regression Tree* (CART), *Artificial Neural Network* (ANN), dan *Support Vector Machine* (SVM) (Scholkopf and Smola, 2002). Metode tersebut banyak digunakan dan dikembangkan karena tingkat akurasi klasifikasi maupun prediksi yang tinggi serta proses komputasi yang efisien (Gajdos, Tarter, Bleiweiss, Herman, Csepel, Estabrook, and Rademaker, 2002; Subashini, Ramalingam, and Palanivel, 2009).

Metode SVM diperkenalkan untuk pertama kalinya oleh Vapnik pada tahun 1995 dan sangat berhasil melakukan prediksi, baik dalam kasus klasifikasi maupun regresi. Metode SVM menemukan solusi yang global optimal dan bekerja dengan memetakan data *training* ke ruang berdimensi tinggi. Dalam ruang berdimensi tinggi, akan dicari klasifikasi yang mampu memaksimalkan *margin* antara dua kelas data. Penggunaan metode ini berusaha untuk menemukan fungsi pemisah yang optimal yang bisa

memisahkan dua set data dari dua kelas yang berbeda atau disebut juga *hyperplane* terbaik diantara fungsi yang tidak terbatas (Gunn, 1998).

Lee dan Mangasarian, (2001) menyatakan bahwa *SVM* memanfaatkan optimasi dengan *quadratic programming* yang apabila digunakan untuk data berdimensi tinggi dan data dengan jumlah besar menjadi kurang efisien. Oleh karena itu para peneliti mengembangkan *smoothing technique* untuk mengubah optimasi yang terbatas menjadi optimasi yang tanpa batas menggunakan formulasi dari *SVM* standar. Ide yang mendasari *SSVM* adalah mengubah formulasi primal *SVM* menjadi problem optimasi yang *smooth* dan bebas kendala. Karena fungsi objektif dari problem optimasi *SVM* tidak memiliki turunan kedua, maka digunakan *smooth function* untuk mendapatkan fungsi objektif yang dapat diperoleh turunannya. *SSVM* memiliki sifat matematik yang penting yaitu kecembungan yang kuat dan terdiferensialkan tak hingga. *Smoothing technique* pada solusi *SVM* telah diaplikasikan oleh Purnami, Embong, dan Zain, (2008a, 2008b, dan 2009) dengan kesimpulan bahwa metode *SSVM* menghasilkan akurasi yang lebih baik dibandingkan analisis diskriminan linier, *neural network*, *decision tree*, *genetic algorithm* dan *supervised fuzzy clustering*.

Lee dan Mangasarian (2001) menemukan *SSVM* dengan menggantikan *plus function* dengan integral dari fungsi sigmoid *neural network*. Selanjutnya penelitian berkembang dengan mencari *smoothing function* yang lebih efisien dari *smooth function* yang telah ditemukan sebelumnya. Beberapa peneliti kemudian memodifikasi *smooth function* kedalam bentuk *polynomial smoothing function*. Yuan dan Huang, (2005) menemukan *quadratic polynomial function* dan *fourth polynomial function*. Luo, Lin, Peng, dan Zhou, (2006) menemukan *piecewise polynomial function*. Yuan, Fan, dan Pu, (2007) menemukan *spline function*. Purnami, dkk (2009a, 2009b) membandingkan keempat fungsi yang ditemukan oleh peneliti-peneliti tersebut pada permasalahan diagnosis kanker payudara. Hasil yang diperoleh adalah *piecewise polynomial function* mempunyai performansi terbaik.

Penelitian selanjutnya dilakukan oleh Wu dan Wang (2013) dengan membandingkan antara *SSVM*, *Forth Polynomial Smooth Support Vector Machine (FPSSVM)*, *Three Order Spline Smooth Support Vector Machine (TSSVM)* dan *Piecewise*

Polynomial Smooth Support Vector Machine (PPSSVM). Penelitian tersebut memberikan kesimpulan bahwa *PPSSVM* memiliki efisiensi, ketepatan serta akurasi yang terbaik.

Penelitian Purnami, dkk (2009a, 2009b) serta Wu dan Wang (2013) mempunyai kesimpulan yang sama bahwa *piecewise polynomial function* mempunyai performansi yang terbaik. Perbedaan dari kedua penelitian tersebut terdapat pada *piecewise polynomial function* yang digunakan.

Berdasarkan keunggulan kedua metode *PPSSVM* tersebut, maka penelitian ini akan mencoba mendapatkan performansi terbaik dari metode *PPSSVM* (Luo, dkk) dan *PPSSVM* (Wu dan Wang) untuk klasifikasi desa tertinggal di Provinsi Kalimantan Timur. Data yang digunakan berasal dari Badan Pusat Statistik (BPS) dan Kementerian Dalam Negeri (Kemendagri) tahun 2011. Dalam penelitian ini metode *PPSSVM* (Luo, dkk) akan disebut sebagai *PPSSVM1* dan metode *PPSSVM* (Wu dan Wang) akan disebut sebagai *PPSSVM2*. *Piecewise polynomial function* (Luo, dkk) akan disebut sebagai *piecewise polynomial function1* dan *piecewise polynomial function* (Wu dan Wang) akan disebut sebagai *piecewise polynomial function2*.

II. METODOLOGI

Support Vector Machine

Pada bentuk yang paling sederhana, *SVM* memisahkan titik-titik dari kelas yang berbeda, misalkan kelas $\{+1\}$ dan $\{-1\}$ dengan *hyperplane* tunggal pada ruang berdimensi banyak yang pada akhirnya partisi-partisi tersebut diselesaikan secara nonlinier. *Hyperplane* yang optimum diperoleh melalui program nonlinier, tepatnya *quadratic programming* (Bertsimas and Shioda, 2007). *Hyperplane* yang mungkin dibentuk dalam memisahkan objek-objek dalam masalah klasifikasi dua kelas mempunyai *decision function* sebagai berikut:

$$f(x) = \mathbf{x}'\mathbf{w} - \gamma \quad (1)$$

Diberikan permasalahan klasifikasi dari sebanyak n objek dalam ruang dimensi R^p sehingga susunan data berupa matrik \mathbf{A} berukuran $n \times p$ dan keanggotaan tiap titik yaitu y_i terhadap kelas $\{+1\}$ atau $\{-1\}$ didefinisikan pada diagonal matriks \mathbf{D} berukuran $n \times n$. Untuk permasalahan klasifikasi dari algoritma *SVM* standar adalah sebagai berikut

($SVM_{\| \cdot \|_2}$):

$$\min_{(\mathbf{w}, \gamma, \mathbf{y}) \in R^{p+1+n}} v\mathbf{e}'\mathbf{y} + \frac{1}{2} \|\mathbf{w}\|_2^2 \quad (2)$$

dengan kendala $\mathbf{D}(\mathbf{A}\mathbf{w} - \mathbf{e}\gamma) + \mathbf{y} \geq \mathbf{e}$

$$\mathbf{y} \geq \mathbf{0}$$

dimana:

v : Parameter yang ditentukan sebagai pengontrol (*trade off*)

\mathbf{y} : Vektor variabel *slack* berukuran $n \times 1$ yang mengukur kesalahan klasifikasi dan bernilai nonnegatif.

\mathbf{e} : Vektor kolom berukuran n dan bernilai 1.

\mathbf{w} : Vektor normal berukuran $p \times 1$.

γ : Nilai bias yang menentukan lokasi relatif *hyperplane* terhadap kelas asli.

Hyperplane margin yang mungkin dibentuk dalam memisahkan objek-objek dalam masalah klasifikasi dua kelas secara linier adalah sebagai berikut:

$$\mathbf{x}'\mathbf{w} - \gamma = 0, \quad (3)$$

Sehingga kedua bidang memisahkan dua kelas dengan *soft margin* yang ditentukan oleh variabel *slack* nonnegatif adalah sebagai berikut:

$$\begin{aligned} \mathbf{x}'\mathbf{w} - \gamma + \mathbf{y}_i &\geq +1 \text{ untuk } \mathbf{x}' = \mathbf{A}_i \text{ dan } \mathbf{D}_{ii} = +1 \\ \mathbf{x}'\mathbf{w} - \gamma - \mathbf{y}_i &\leq -1 \text{ untuk } \mathbf{x}' = \mathbf{A}_i \text{ dan } \mathbf{D}_{ii} = -1 \end{aligned} \quad (4)$$

Dimana vektor \mathbf{x} adalah bagian dari matriks \mathbf{A} berukuran $p \times 1$. Dimana $i = 1, 2, \dots, n$. Persamaan di atas merupakan kendala bagi fungsi SVM yang dapat ditulis dalam satu persamaan matriks sebagai berikut:

$$\mathbf{D}(\mathbf{A}\mathbf{w} - \mathbf{e}\gamma) + \mathbf{y} \geq \mathbf{e} \text{ dan } \mathbf{y} \geq \mathbf{0} \quad (5)$$

Penyelesaian persamaan (1) akan mudah diselesaikan dengan meminimumkan fungsi Lagrange terhadap \mathbf{w} , γ , \mathbf{y} serta meminimumkan terhadap Lagrange *multiplier* $\boldsymbol{\alpha}$ dan $\boldsymbol{\beta}$.

$$L(\mathbf{w}, \gamma, \mathbf{y}, \boldsymbol{\alpha}, \boldsymbol{\beta}) = \frac{1}{2} \|\mathbf{w}\|_2^2 + v\mathbf{e}'\mathbf{y} - \boldsymbol{\alpha}'(\mathbf{D}(\mathbf{A}\mathbf{w} - \mathbf{e}\gamma) - \mathbf{e} + \gamma) - \boldsymbol{\beta}'\mathbf{y} \quad (6)$$

SVM dengan bidang pemisah yang nonlinier diperoleh dengan mentransformasi formulasi SVM standar sebagai berikut:

$$\mathbf{w} = \mathbf{A}'\mathbf{D}\mathbf{u} \tag{7}$$

Dengan mensubstitusikan (7) kedalam model (2) maka problem nonlinier diperoleh sebagai berikut:

$$\min_{(\mathbf{w}, \gamma, \mathbf{y}) \in \mathbb{R}^{p+1+n}} \mathbf{v}\mathbf{e}'\mathbf{y} + \frac{1}{2} \|\mathbf{A}'\mathbf{D}\mathbf{u}\|_2^2 \tag{8}$$

dengan kendala $\mathbf{D}(\mathbf{A}\mathbf{A}'\mathbf{D}\mathbf{u} - \mathbf{e}\gamma) + \mathbf{y} \geq \mathbf{e}$

$$\mathbf{y} \geq \mathbf{0}$$

Dengan menggantikan $\mathbf{A}'\mathbf{A}$ dengan kernel nonlinier $K(\mathbf{A}, \mathbf{A}')$ menghasilkan *nonlinear generalized SVM* adalah sebagai berikut:

$$\min_{(\mathbf{w}, \gamma, \mathbf{y}) \in \mathbb{R}^{p+1+n}} \mathbf{v}\mathbf{e}'\mathbf{y} + \frac{1}{2} \mathbf{u}'\mathbf{D}'K(\mathbf{A}, \mathbf{A}')\mathbf{D}\mathbf{u} \tag{9}$$

dengan kendala $\mathbf{D}(K(\mathbf{A}\mathbf{A}')\mathbf{D}\mathbf{u} - \mathbf{e}\gamma) + \mathbf{y} \geq \mathbf{e}$

$$\mathbf{y} \geq \mathbf{0}$$

SSVM linier

Pendekatan *smoothing* Lee dan Mangasarian (2001) menjadikan variabel slack \mathbf{y} menjadi 2-norm yang diboboti $\frac{\nu}{2}$. Dengan demikian problem optimasi pada *SSVM* adalah:

$$\min_{\mathbf{w}, \gamma, \mathbf{y}} \frac{\nu}{2} \mathbf{y}'\mathbf{y} + \frac{1}{2} (\mathbf{w}'\mathbf{w} + \gamma^2) \tag{10}$$

dengan kendala $\mathbf{D}(\mathbf{A}\mathbf{w} - \mathbf{e}\gamma) + \mathbf{y} \geq \mathbf{e}$

$$\mathbf{y} \geq \mathbf{0},$$

di mana untuk memperoleh solusi problem (10), kendala-kendalanya dapat ditulis sebagai berikut:

$$\mathbf{y} = (\mathbf{e} - \mathbf{D}(\mathbf{A}\mathbf{w} - \mathbf{e}\gamma))_+ \tag{11}$$

Substitusi persamaan (11) terhadap persamaan (10) menghasilkan fungsi objektif tanpa kendala sebagai berikut:

$$\min_{\mathbf{w}, \gamma} \frac{\nu}{2} \|(\mathbf{e} - \mathbf{D}(\mathbf{A}\mathbf{w} - \mathbf{e}\gamma))_+\|_2^2 + \frac{1}{2}(\mathbf{w}'\mathbf{w} + \gamma^2) \tag{12}$$

Dimana $(\bullet)_+$ menggantikan komponen-komponen bernilai negatif dengan nilai nol. Fungsi objektif dalam persamaan (12) tidak memiliki turunan kedua. Lee dan Mangasarian mengusulkan *smoothing technique* yang menggantikan fungsi plus $(\bullet)_+$ dengan $p(x, \alpha)$ yaitu integral dari fungsi *sigmoid neural network* $(1 + \exp(-\alpha x))^{-1}$ atau dapat dituliskan sebagai berikut:

$$p(x, \alpha) = x + \frac{1}{\alpha} \ln(1 + \exp(-\alpha x)), \alpha > 0 \tag{13}$$

di mana α adalah *smoothing parameter*.

SSVM nonlinier

Dalam kasus non linier, dengan memasukkan fungsi kernel pada persamaan (12) maka problem optimasi SSVM non linier adalah sebagai berikut:

$$\min_{(\mathbf{u}, \gamma) \in \mathbb{R}^{n+1}} \Phi_\alpha(\mathbf{w}, \gamma) := \min_{(\mathbf{u}, \gamma) \in \mathbb{R}^{n+1}} \frac{\nu}{2} \|p(\mathbf{e} - \mathbf{D}(K(\mathbf{A}, \mathbf{A}')\mathbf{D}\mathbf{u} - \mathbf{e}\gamma), \alpha)\|_2^2 + \frac{1}{2}(\mathbf{u}'\mathbf{u} + \gamma^2) \tag{14}$$

Program optimasi tersebut dapat diselesaikan dengan algoritma Newton-Armijo. Pada algoritma Newton-Armijo diperoleh nilai \mathbf{w} dan γ yang konvergen. Dengan demikian *decision function* yang diperoleh untuk kasus klasifikasi linier adalah :

$$\hat{f}(x) = \text{sign}(\mathbf{x}'\mathbf{w} - \gamma), \tag{15}$$

Sedangkan *decision function* untuk kasus klasifikasi nonlinier adalah sebagai berikut:

$$\hat{f}(x) = \text{sign}(\mathbf{x}'\mathbf{w} - \gamma) = \text{sign}(\mathbf{u}'\mathbf{D}'K(\mathbf{A}, \mathbf{A}')\mathbf{w} - \gamma), \tag{16}$$

Seleksi Parameter

Permasalahan dari pemilihan parameter terbaik untuk membuat performansi generalisasi yang lebih baik pada *learning task* disebut seleksi model. Metodologi *Uniform Design (UD)* digunakan untuk efisiensi, *robust* dan seleksi model pada SVM (Huang, Lee, Lin, and Huang, 2007). Pada penelitian ini menggunakan *k-fold cross validation* dalam pembagian data *training-testing*. Metode ini melakukan pengulangan sebanyak *k* kali untuk membagi sebuah himpunan contoh (sampel) secara acak menjadi *k-subset* yang saling bebas. Setiap ulangan disisakan satu *subset* untuk *testing* dan sisanya digunakan untuk *training*. Hasil dari percobaan dan pembuktian teoritis, menunjukkan bahwa *k-fold cross validation* adalah pilihan terbaik untuk mendapatkan hasil validasi yang akurat (Kohavi, 1995).

Polynomial Smoothing Function

Penelitian berkembang dengan mencari *smooth function* yang lebih efisien dari *smooth function* yang telah ditemukan sebelumnya. Beberapa peneliti kemudian memodifikasi *smooth function* kedalam bentuk *polynomial smooth function*, yaitu:

1. *Quadratic polynomial function*

$$f_1(x, h) = \begin{cases} x, & x \geq \frac{1}{h} \\ \frac{h}{4}x^2 + \frac{1}{2}x + \frac{1}{4h}, & -\frac{1}{k} < x < \frac{1}{h} \\ 0, & x \leq -\frac{1}{h} \end{cases} \quad (17)$$

2. *Fourth polynomial function*

$$f_2(x, h) = \begin{cases} x, & x \geq \frac{1}{h} \\ \frac{1}{16k}(hx + 1)^3(hx - 3), & -\frac{1}{h} < x < \frac{1}{h} \\ 0, & x \leq -\frac{1}{h} \end{cases} \quad (18)$$

3. *Spline function*

$$f_3(x, h) = \begin{cases} 0, & x < -\frac{1}{h} \\ \frac{h^2}{6}x^3 + \frac{h}{2}x^2 + \frac{1}{2}x + \frac{1}{6h}, & -\frac{1}{h} \leq x < 0 \\ -\frac{h^2}{6}x^2 + \frac{h}{2}x^2 + \frac{1}{2}x + \frac{1}{6h}, & 0 \leq x \leq \frac{1}{h} \\ x, & \frac{1}{h} < x \end{cases} \quad (19)$$

4. Piecewise polynomial function1

Fungsi yang diusulkan oleh Luo, dkk (2006) ini dirumuskan dengan meminimalkan 2-norm pada fungsi error. Persamaan *picewise polynomial function* adalah sebagai berikut :

$$f_4(x, h) = \begin{cases} x, & x \geq \frac{1}{h} \\ \frac{1}{32}(hx + 1)^3 \left(h^2x^3 - 3hx^2 + x + \frac{5}{h} \right), & -\frac{1}{h} < x < \frac{1}{h} \\ 0, & x \leq -\frac{1}{h} \end{cases} \quad (20)$$

5. Piecewise Polynomial Function2

Pada penelitian Wu dan Wang (2013) *piecewise polynomial function* yang digunakan berbeda dengan yang digunakan Luo, dkk (2006).

$$f_5(x, h) = \begin{cases} 0, & x < -\frac{1}{3h}, \\ \frac{3}{2}h^2 \left(x + \frac{1}{3h} \right)^3, & -\frac{1}{3h} \leq x < 0, \\ x + \frac{3}{2}h^2 \left(\frac{1}{3h} - x \right)^3, & 0 \leq x \leq \frac{1}{3h}, \\ x, & x > \frac{1}{3h}, \end{cases} \quad (21)$$

Performansi Fungsi

Untuk mengetahui performansi suatu fungsi dapat dilakukan dengan melihat selisih antara *smooth function* dengan *plus function*. Pada penelitian ini digunakan Lemma yang pernah digunakan pada penelitian sebelumnya.

Lemma 1 (Lee dan Mangasarian, 2001):

$p(x, \alpha) = x + \frac{1}{\alpha} \log(1 + \exp(-\alpha x)), \alpha > 0$, dan x_+ adalah *plus function*. Untuk $x \in R$

dan $|x| < \rho$, maka akan diperoleh hasil sebagai berikut:

- (i) $p(x, \alpha) \geq x_+$;
- (ii) $p > 0, |x| < p, p(x, \alpha)^2 - (x_+)^2 \leq (\log 2 / \alpha)^2 + (2\rho / \alpha) \log 2$.

Kekonvergenan Fungsi

Analisis kekonvergenan pada penelitian ini dilakukan dengan membuktikan bahwa problem optimasi kedua metode *PPSSVM* dapat mendekati problem optimasi metode *SVM* standar ketika h mendekati tak hingga. Definisi dan Teorema yang digunakan adalah sebagai berikut:

Definisi 1 (Boyd, 2004):

(i) *Triangle inequality*:

$$f(x+y) \leq f(x) + f(y)$$

(ii) Homogeniti dari *norm*

$$f(tx) = |t| f(x) \quad \forall x \in R \text{ and } t \in R$$

(iii) Subset x dari *euclidean space* R^n disebut *compact* jika x adalah *closed and bounded*.

Teorema 1 (Lee dan Mangasarian, 2001) Jika $\mathbf{A} \in R^{m \times n}$, $\boldsymbol{\gamma} \in R^{m \times 1}$, definisi dari fungsi riil

$f(\mathbf{x}): R^n \rightarrow R$ dan $g(\mathbf{x}, \alpha): R^n \times N \rightarrow R$ adalah sebagai berikut:

$$f(\mathbf{x}) = \frac{1}{2} \|(\mathbf{Ax} - \boldsymbol{\gamma})_+\|_2^2 + \frac{1}{2} \|\mathbf{x}\|_2^2 \tag{22}$$

$$g(\mathbf{x}, \alpha) = \frac{1}{2} \|p(\mathbf{Ax} - \boldsymbol{\gamma}, \alpha)\|_2^2 + \frac{1}{2} \|\mathbf{x}\|_2^2 \tag{23}$$

dengan $\alpha > 0$, maka:

(i) $f(\mathbf{x})$ dan $g(\mathbf{x}, \alpha)$ adalah *convex function*.

(ii) \mathbf{x}^* adalah solusi unik untuk $\min_{x \in R^n} f(\mathbf{x})$ dan \mathbf{x}_α^* juga merupakan solusi unik dari

$$\min_{x \in R^n} g(\mathbf{x}, \alpha)$$

(iii) Untuk $\forall \alpha > 0$ maka akan diperoleh pertidaksamaan:

$$\|\mathbf{x}_\alpha^* - \mathbf{x}^*\|_2^2 \leq \frac{\nu}{2} \left(\left(\frac{\log 2}{\alpha} \right) + 2\xi \frac{\log 2}{\alpha} \right) \tag{24}$$

Dimana ξ didefinisikan:

$$\xi = \max_{1 \leq i \leq m} |(\mathbf{Ax}^* - \boldsymbol{\gamma})_i|$$

(iv) \mathbf{x}^* dan \mathbf{x}_α^* memenuhi $\lim_{\alpha \rightarrow \infty} \mathbf{x}_\alpha^* = \mathbf{x}^*$ (25)

Evaluasi Performansi Klasifikasi

1. Akurasi, *sensitivity* dan *specificity*

Ukuran ketepatan klasifikasi dapat dilihat dari akurasi klasifikasi. Akurasi menunjukkan performansi teknik klasifikasi secara keseluruhan, semakin tinggi akurasi klasifikasi berarti semakin baik performansi teknik klasifikasi.

Tabel 1. Confusion Matrix Untuk Hasil Klasifikasi Biner

Kelas sebenarnya	Kelas prediksi	
	Positif	Negatif
Positif	tp	fn
Negatif	fp	tn

$$\text{Akurasi klasifikasi (\%)} = \frac{tp + tn}{tp + fp + tn + fn} \tag{26}$$

$$\text{Sensitivity (\%)} = \frac{tp}{tp + fn} \tag{27}$$

$$\text{Specificity (\%)} = \frac{tn}{fp + tn} \tag{28}$$

2. Kurva ROC (Receiver Operating Characteristics)

Kurva ROC adalah gambaran dua dimensi dari kinerja suatu pengklasifikasian. Suatu metode yang umum digunakan untuk menghitung nilai kinerja dari pengklasifikasian adalah dengan menghitung luas daerah dibawah kurva ROC, disebut dengan *Area Under the Receiver Operating Characteristics Curve (AUC)*. Nilai AUC selalu berada diantara 0 dan 1. Untuk suatu kurva ROC yang memadai, maka letaknya selalu berada di daerah sebelah atas dari garis diagonal (0,0) dan (1,1), sehingga tidak ada nilai AUC yang lebih kecil dari 0,5.

Tabel 2. Kategori Pengklasifikasian Berdasarkan Nilai AUC

Nilai AUC	Model diklasifikasikan sebagai
0.90 – 1.00	<i>Excellent</i>
0.80 – 0.90	<i>Good</i>
0.70 – 0.80	<i>Fair</i>
0.60 – 0.70	<i>Poor</i>
0.50 – 0.60	<i>Fail</i>

Sumber: (Mohanty et al., 2011)

Sumber Data

Data yang digunakan dalam penelitian ini adalah data sekunder. Variabel respon berasal dari Kemendagri yaitu status ketertinggalan desa pada Profil Desa dan Kelurahan 2011: Data Dasar Tipologi Klasifikasi, Kategori Desa Kelurahan (2012). Variabel prediktor berasal dari BPS yaitu data PODES Provinsi Kalimantan Timur Tahun 2011, yaitu rasio jumlah SD, rasio jumlah SMP, rasio jumlah dokter, rasio jumlah bidan, persentase sarana kesehatan, rasio jumlah toko/warung kelontong, rasio jumlah pasar tanpa bangunan, rasio jumlah koperasi, persentase keluarga yang tinggal di pemukiman kumuh, persentase keluarga yang tinggal di bantaran/tepi sungai, persentase keluarga petani, persentase warga yang menerima jamkesmas/jamkesda, persentase keluarga pengguna listrik, persentase rumah tangga yang memiliki telepon kabel, dan persentase surat miskin yang dikeluarkan desa. Penelitian dilakukan terhadap 1465 desa dan pengolahan data dilakukan dengan *software* MATLAB.

III. HASIL DAN PEMBAHASAN

Analisis Performansi *Smoothing Function*

Pada tahap awal akan dipaparkan perbandingan performansi dari *smoothing function* terhadap *plus function* pada *piecewise polynomial function1* dan *piecewise polynomial function2*. Teorema yang akan digunakan berdasarkan pada penelitian Yuan, dkk (2007).

Teorema 2. *Piecewise polynomial function1*, $f_4(x, h)$ mempunyai sifat:

- (i) $f_4(x, h)$ mempunyai turunan kedua terhadap x .
- (ii) Untuk semua $x \in R$, $f_4(x, h) \geq x_+$;
- (iii) Untuk semua $x \in R$, maka $f_4(x, h)^2 - x_+^2 \leq \frac{1}{28}h^2$

Pembuktian:

- (i) Turunan pertama dan kedua dari $f_4(x, h)$ adalah sebagai berikut:

$$f_4(x, h) = \begin{cases} x, & x \geq \frac{1}{h} \\ \frac{1}{32}(hx + 1)^3 \left(h^2 x^3 - 3hx^2 + x + \frac{5}{h} \right), & -\frac{1}{h} < x < \frac{1}{h} \\ 0, & x \leq -\frac{1}{h} \end{cases}$$

Sehingga:

$$\nabla f_4(x, h) = \begin{cases} 1, & x \geq \frac{1}{h}, \\ \frac{1}{32}(hx + 1)^2 (6h^3 x^3 - 12h^2 x^2 - 2hx + 16), & -\frac{1}{h} < x < \frac{1}{h}, \\ 0, & x \leq -\frac{1}{h} \end{cases} \quad (29)$$

$$\nabla^2 f_4(x, h) = \begin{cases} 0, & x \geq \frac{1}{h}, \\ \frac{1}{32}(hx + 1)(3h^5 x^3 - 3h^4 x^2 - 3h^3 x + 3h^2), & -\frac{1}{h} < x < \frac{1}{h}, \\ 0, & x \leq -\frac{1}{h} \end{cases} \quad (30)$$

Sehingga diperoleh kesimpulan bahwa $f_4(x, h)$ mempunyai turunan kedua terhadap x .

(ii) Untuk membuktikan $f_4(x, h) \geq x_+$, maka pembuktiannya adalah sebagai berikut:

Jika $-\frac{1}{h} \leq x \leq \frac{1}{h}$ maka, dengan menggunakan persamaan

$$f_4(x, h) = \frac{1}{32}(hx + 1)^3 \left(h^2 x^3 - 3hx^2 + x + \frac{5}{h} \right)$$

$$f_4'(x, h) = \frac{1}{32}(hx + 1)^2 (6h^3 x^3 - 12h^2 x^2 - 2hx + 16)$$

$$\Rightarrow f_4'(-\frac{1}{h}, h) = 0$$

Hal tersebut mengindikasikan bahwa $f_4(x, h)$ monoton naik, Sehingga $f_4(x, h) \geq (x)_+$

Untuk mencari titik monoton $f_4(x, h) \geq (x)_+$ menggunakan persamaan:

$$Q(x) = f_4(x, h) - (x)_+$$

Jika $-\frac{1}{h} \leq x \leq \frac{1}{h}$ maka:

$$Q(x) = f_4(x, h) - (x)_+ = \left(\frac{1}{32}(hx + 1)^3 \left(h^2 x^3 - 3hx^2 + x + \frac{5}{h} \right) \right) - x$$

$$Q'(x) = \frac{1}{32}(hx + 1)^2 (6h^3 x^3 - 12h^2 x^2 - 2hx + 16) - 1$$

Kemudian gunakan turunan kedua dari $Q(x)$

$$Q''(x) = \frac{1}{32}(hx+1)(3h^5x^3 - 3h^4x^2 - 3h^3x + 3h^2) = 0$$

$$= \frac{1}{32}(hx+1)(hx-1)^2 = 0$$

Sehingga $Q(x)$ monoton naik pada $[-\frac{1}{h}, \frac{1}{h}]$ dan jika $-\frac{1}{h} \leq x \leq \frac{1}{h}$ diperoleh

$$f_4(x, h) \geq (x)_+$$

(iii) Jika $x < h$ atau $x > \frac{1}{h}$, maka nilai dari $f_4(x, h)$ dan x_+ adalah sama, sehingga

$$f_4(x, h)^2 - x_+^2 = 0$$

Jika $-\frac{1}{h} < x < \frac{1}{h}$, untuk mendapatkan hasil, maka a ditransformasi menjadi $a = hx$,

$$a \in [0, 1].$$

Sehingga $s(x) = f_4(x, h)^2 - x_+^2$

$$= \left[\frac{1}{32}(hx+1) \left(h^2x^3 - 3hx^2 + x + \frac{5}{h} \right) \right]^2 - x^2,$$

Setelah mensubstitusi $a = hx$ ke dalam persamaan di atas diperoleh:

$$s(x) = s(a) = \frac{1}{704h^2} \left[(a+1)^6 (a^3 - 3a^2 + a + 5)^2 - 704a^2 \right] \tag{31}$$

Untuk $\forall a \in [0, 1]$, titik optimum pada $s(a)$ adalah $a = 3.984 \times 10^{-5}$. Sehingga

$$s(x) = f_4(x, h)^2 - x_+^2 \leq \frac{1}{28h^2}$$

Performansi *piecewise polynomial function* terhadap *plus function* dibuktikan oleh Wu dan Wang dalam penelitiannya juga berdasarkan teorema pada penelitian dari Yuan dkk (2007).

Berdasarkan hasil pada Lemma 1, Theorema 1 dan hasil penelitian Wu dan Wang, maka diperoleh perbandingan performansi dari *smoothing function* adalah sebagai berikut:

Teorema 3 (Lee dan Mangasarian, 2001). Jika $\rho = \frac{1}{k}$, dan $h > 0$. Maka hasil dari performansi *smoothing function* adalah:

(i) Jika *smooth function* yang didefinisikan pada (12) diperoleh:

$$p(x, h)^2 - x_+^2 \leq \left(\frac{\log 2}{h}\right)^2 + \frac{2\rho}{h} \log 2$$

$$= (\log^2 2 + 2 \log 2) \frac{1}{h^2} \approx 0.69267 \frac{1}{h^2} \tag{32}$$

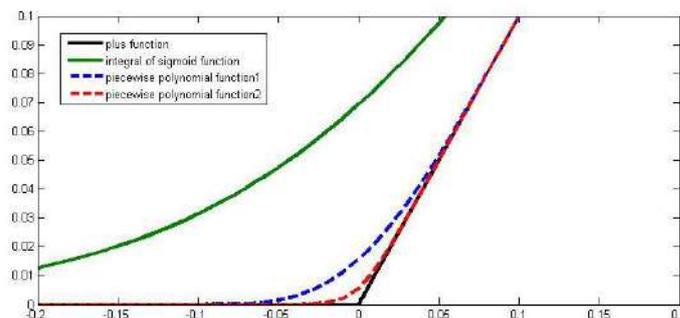
(ii) Jika *smooth function* yang didefinisikan pada (20) diperoleh:

$$f_4(x, h)^2 - x_+^2 \leq \frac{1}{28h^2} \approx 0.03571 \frac{1}{h^2} \tag{33}$$

(iii) Jika *smooth function* yang didefinisikan pada (21) diperoleh:

$$f_5(x, h)^2 - x_+^2 \leq \frac{1}{216h^2} \approx 0.00463 \frac{1}{h^2} \tag{34}$$

Theorem 3 menunjukkan bahwa *piecewise polynomial function2* mempunyai performansi yang lebih baik dibandingkan *piecewise polynomial function1* untuk *plus function* x_+ . Ketika h mempunyai nilai yang pasti, maka akan sangat mudah mendapatkan perbedaan dari *smooth function* di atas. Untuk menunjukan secara jelas perbedaan performansi *smooth function* dengan *plus function*, maka kita gunakan $h=10$ untuk semua fungsi tersebut dan hasilnya dapat dilihat pada Gambar 1.



Gambar 1. Perbandingan performansi *smoothing function* ($h=10$)

Pada Gambar 1 terlihat bahwa *piecewise polynomial function2* lebih mendekati pada kurva *plus function*. Hal tersebut menunjukkan bahwa *piecewise polynomial function2* mempunyai performansi yang lebih baik dibandingkan dengan fungsi yang lain.

Konvergensi Model PPSSVM

Pembuktian untuk konvergensi dari model *PPSSVM1* dan *PPSSVM2* akan diperoleh ketika problem optimasi kedua model tersebut mendekati model awal pada (11), yaitu ketika h mendekati tak hingga. Teorema untuk *polynomial function* yang diterapkan pada model SSVM dikembangkan oleh Yuan, dkk (2007).

Teorema 4. Jika $\mathbf{A} \in R^{m \times n}$, $\boldsymbol{\gamma} \in R^{m \times 1}$, definisi dari fungsi riil $f(\mathbf{x}): R^n \rightarrow R$ dan $g_4(\mathbf{x}, h): R^n \times N \rightarrow R$ adalah sebagai berikut:

$$f(\mathbf{x}) = \frac{1}{2} \|(\mathbf{Ax} - \boldsymbol{\gamma})_+\|_2^2 + \frac{1}{2} \|\mathbf{x}\|_2^2 \tag{35}$$

$$g_4(\mathbf{x}, h) = \frac{1}{2} \|f_4(\mathbf{Ax} - \boldsymbol{\gamma}, h)\|_2^2 + \frac{1}{2} \|\mathbf{x}\|_2^2 \tag{36}$$

dengan $\forall h \geq 1$, maka:

Jika $f_4(x, h)$ adalah *piecewise polynomial function 1*, hasil yang diperoleh adalah:

- (i) $f(\mathbf{x})$ dan $g_4(\mathbf{x}, h)$ adalah *convex function*.
- (ii) \mathbf{X}^* adalah solusi unik untuk $\min_{\mathbf{x} \in R^n} f(\mathbf{x})$ dan \mathbf{x}_h^* juga merupakan solusi unik dari

$$\min_{\mathbf{x} \in R^n} g_4(\mathbf{x}, h)$$

- (iii) Untuk $\forall h \geq 1$ \mathbf{X}^* dan \mathbf{x}_h^* keduanya memenuhi:

$$\|\mathbf{x}_h^* - \mathbf{x}^*\|_2^2 \leq \frac{\nu}{2} \left(\frac{1}{28h^2} \right) \tag{37}$$

- (iv) \mathbf{X}^* dan \mathbf{x}_h^* memenuhi $\lim_{h \rightarrow \infty} \mathbf{x}_h^* = \mathbf{x}^*$ (38)

Pembuktian:

- (i) $f: R^n \rightarrow R$, dan $0 \leq \theta \leq 1$

Dengan melihat pertidaksamaan pada *triangle inequality* dan persamaan pada *homogeneity of a norm*, maka:

$$f(\theta \mathbf{x}_1 + (1 - \theta) \mathbf{x}_2) \leq f(\theta \mathbf{x}_1) + f((1 - \theta) \mathbf{x}_2) = \theta f(\mathbf{x}_1) + (1 - \theta) f(\mathbf{x}_2)$$

Sehingga $f(\mathbf{x})$ adalah *convex function*.

Pembuktian terhadap $g_4(\mathbf{x}, h)$ dapat dilakukan dengan langkah yang sama.

- (ii) $L_v(f(\mathbf{x}))$ adalah *level set* dari $f(\mathbf{x})$. $L_v(g_4(\mathbf{x}, h))$ adalah *level set* dari $g_4(\mathbf{x}, h)$.

Ketika $f_4(x, h) \geq x_+$, maka akan didapatkan:

$$L_v(g_4(\mathbf{x}, h)) \subseteq L_v(f(\mathbf{x})) \subseteq \{\mathbf{x} \mid \|\mathbf{x}\|_2^2 \leq 2v\}$$

Oleh karena itu, $L_v(f(\mathbf{x}))$ dan $L_v(g_4(\mathbf{x}, h))$ adalah *compact subset* pada \mathbb{R}^n .

Dengan menggunakan sifat *convexity* pada $f(\mathbf{x})$ dan $g_4(\mathbf{x}, h)$ untuk $h > 0$, maka diperoleh solusi unik $\min_{\mathbf{x} \in \mathbb{R}^n} f(\mathbf{x})$ untuk $f(\mathbf{x})$ dan $\min_{\mathbf{x} \in \mathbb{R}^n} g_4(\mathbf{x}, h)$ untuk $g_4(\mathbf{x}, h)$.

- (iii) Dengan menggunakan *first order optimization* dan mempertimbangkan sifat *convexity* pada $f(\mathbf{x})$ dan $g_4(\mathbf{x}, h)$, maka pertidaksamaan yang diperoleh adalah:

$$\begin{aligned} f(\mathbf{x}_h^*) - f(\mathbf{x}^*) &\geq \nabla f(\mathbf{x}^*)(\mathbf{x}_h^* - \mathbf{x}^*) + \frac{1}{2} \|\mathbf{x}_h^* - \mathbf{x}^*\|_2^2 \\ &= \frac{1}{2} \|\mathbf{x}_h^* - \mathbf{x}^*\|_2^2 \end{aligned}$$

$$\begin{aligned} g_4(\mathbf{x}^*, h) - g_4(\mathbf{x}_h^*, h) &\geq \nabla g_4(\mathbf{x}_h^*, h)(\mathbf{x}^* - \mathbf{x}_h^*) + \frac{1}{2} \|\mathbf{x}_h^* - \mathbf{x}^*\|_2^2 \\ &= \frac{1}{2} \|\mathbf{x}_h^* - \mathbf{x}^*\|_2^2 \end{aligned}$$

Jika kedua persamaan diatas dijumlahkan dengan catatan $f_4(x, h) \geq x_+$ maka akan diperoleh:

$$\begin{aligned} \|\mathbf{x}_h^* - \mathbf{x}^*\|_2^2 &\leq f(\mathbf{x}_h^*) - f(\mathbf{x}^*) + g_4(\mathbf{x}^*, h) - g_4(\mathbf{x}_h^*, h) \\ &= (g_4(\mathbf{x}^*, h) - f(\mathbf{x}^*)) - (g_4(\mathbf{x}_h^*, h) - f(\mathbf{x}_h^*)) \leq g_4(\mathbf{x}^*, h) - f(\mathbf{x}^*) \\ &= \frac{1}{2} \|f_4(\mathbf{A}\mathbf{x}_h^* - \boldsymbol{\gamma}, h)\|_2^2 - \frac{1}{2} \|(\mathbf{A}\mathbf{x}^* - \boldsymbol{\gamma})_+\|_2^2 \end{aligned}$$

Berdasarkan pada hasil (iii) pada Theorema 4.1.1 maka diperoleh:

$$\|\mathbf{x}_h^* - \mathbf{x}^*\|_2^2 \leq \frac{v}{2} \left(\frac{1}{28h^2} \right).$$

Sehingga diperoleh kesimpulan bahwa persamaan (4.12) adalah benar.

(iv) Ketika h mendekati tak hingga pada (4.12), maka diperoleh

$$\lim_{h \rightarrow \infty} \|\mathbf{x}_h^* - \mathbf{x}^*\|_2^2 \leq \lim_{h \rightarrow \infty} \frac{\nu}{2} \left(\frac{1}{28h^2} \right) = 0$$

Sehingga $\lim_{h \rightarrow \infty} \mathbf{x}_h^* = \mathbf{x}^*$

Hasil dari (iv) menjelaskan bahwa problem optimasi model *PPSSVM1* mendekati model awal (11) ketika h mendekati positif tak hingga, atau dengan kata lain *PPSSVM1* konvergen ke model awal.

Konvergensi *PPSSVM2* telah dibuktikan dalam penelitian Wu dan Wang (2013) dengan hasil yang diperoleh adalah:

(i) $f(\mathbf{x})$ dan $g_5(\mathbf{x}, h)$ adalah *convex function*.

(ii) \mathbf{X}^* adalah solusi unik untuk $\min_{\mathbf{x} \in R^n} f(\mathbf{x})$ dan \mathbf{x}_h^{**} juga merupakan solusi unik dari $\min_{\mathbf{x} \in R^n} g_5(\mathbf{x}, h)$

(iii) Untuk $\forall h \geq 1$ \mathbf{X}^* dan \mathbf{x}_h^{**} keduanya memenuhi

$$\|\mathbf{x}_h^{**} - \mathbf{x}^*\|_2^2 \leq \frac{\nu}{2} \left(\frac{1}{216h^2} \right) \tag{39}$$

(iv) \mathbf{X}^* dan \mathbf{x}_h^{**} memenuhi $\lim_{h \rightarrow \infty} \mathbf{x}_h^{**} = \mathbf{x}^*$ (40)

Hasil dari (iv) ini menjelaskan bahwa problem optimasi model *PPSSVM2* mendekati model awal (11) ketika h mendekati positif tak hingga. Hasil analisis teoritis tersebut menunjukkan bahwa model *PPSSVM2* mempunyai performansi yang lebih baik dibandingkan dengan model *PPSSVM1*. Hal ini dapat terlihat dari nilai problem optimasi model *PPSSVM2* yang lebih kecil dibandingkan dengan nilai problem optimasi model *PPSSVM1*.

Aplikasi Model *PPSSVM* untuk Klasifikasi Desa Tertinggal di Provinsi Kalimantan Timur

Pada penelitian ini fungsi kernel yang digunakan pada tahapan klasifikasi desa tertinggal di Provinsi Kalimantan Timur adalah kernel Gaussian. Domain pencarian parameter μ pada fungsi kernel Gaussian ditentukan dengan menentukan jarak minimum

antara objek dengan rata-rata vektor dari matriks yang disusun oleh nilai-nilai kelima belas variabel prediktor.

Tabel 3. Tingkat Akurasi Model SSVM, PPSSVM1 dan PPSSVM2

Model	Parameter		Akurasi data <i>training</i> (%)	Akurasi data <i>testing</i> (%)
	<i>Best v</i>	<i>Best μ</i>		
[1]	[2]	[3]	[4]	[5]
SSVM	0.7499	5.05×10^{-4}	90.17	89.38
PPSSVM1	10.000	1.97×10^{-4}	90.20	89.45
PPSSVM2	133.3521	7.65×10^{-5}	90.06	89.59

Keterangan : Nilai-nilai yang dicetak tebal menunjukkan akurasi tertinggi

Hasil pengolahan yang ditunjukkan pada Tabel 3 menunjukkan bahwa tingkat akurasi data *testing* menggunakan model SSVM adalah 89,38% sedangkan dengan menggunakan metode PPSSVM1 adalah 89,45% dan metode PPSSVM2 sebesar 89,59%. Hal ini menunjukkan bahwa penggunaan metode PPSSVM2 menghasilkan akurasi tertinggi untuk data *testing* pada kasus klasifikasi desa tertinggal di Provinsi Kalimantan Timur menggunakan data PODES 2011. Berdasarkan ulasan di atas maka akan dicontohkan model PPSSVM2 untuk data terpartisi 90:10 adalah sebagai berikut:

Model PPSSVM2

$$\hat{f}(x) = \text{sign}(g(x)) = \text{sign}(\mathbf{x}'\mathbf{w} - \gamma)$$

$$g(x) = \mathbf{u}'\mathbf{D}'K(\mathbf{A}_{\text{training}}, \mathbf{A}_{\text{testing}}) - \gamma$$

$$= \begin{pmatrix} -0.41019 \\ -6.50612 \\ -1.25309 \\ \vdots \\ -0.05606 \end{pmatrix}_{(1.319 \times 1)} \begin{pmatrix} 1 & 0 & 0 & \dots & 0 \\ 0 & -1 & 0 & \dots & 0 \\ 0 & 0 & 1 & \dots & 0 \\ \vdots & & \ddots & & \vdots \\ 0 & 0 & 0 & \dots & -1 \end{pmatrix}_{(1.319 \times 1.319)} K(\mathbf{A}_{\text{training}}, \mathbf{A}_{\text{testing}})_{(1.319 \times 146)} - (0.114136)'_{(146 \times 1)}$$

dengan

$$K(\mathbf{A}_{\text{training}}, \mathbf{A}_{\text{testing}}) = -\mu \|\mathbf{A}_{(i)\text{training}} - \mathbf{A}_{(i)\text{testing}}\|_2$$

$$= -7.65 \times 10^{-5} \|\mathbf{A}_{(i)\text{training}} - \mathbf{A}_{(i)\text{testing}}\|_2$$

maka diperoleh:

$$g(x)' = \begin{pmatrix} 1 \\ -1 \\ 1 \\ \cdot \\ \cdot \\ \cdot \\ -1 \end{pmatrix}_{(146 \times 1)}$$

Sehingga $g(x)$ merupakan vektor baris berukuran $1 \times$ (jumlah data testing) dan masing-masing tanda positif atau negatif setiap komponen vektor tersebut merupakan prediksi untuk klasifikasi desa tertinggal di Provinsi Kalimantan Timur Tahun 2011.

Evaluasi Performansi Klasifikasi

Evaluasi klasifikasi berdasarkan nilai akurasi, *sensitivity* dan *specificity* dapat ditunjukkan pada Tabel 4. Tingkat akurasi untuk model *SSVM* dan kedua model *PPSSVM* secara umum lebih dari 90%, hanya pada data terpartisi 80:20 tingkat akurasinya kurang dari nilai tersebut. Selain itu pada model *SSVM* data terpartisi 90:10 nilai akurasinya sebesar 88,36%, nilai ini relatif berbeda dengan kedua model lainnya dengan nilai akurasi sebesar 90,41%.

Nilai *specificity* pada data *testing* 40% dan 50% untuk model *SSVM* dan kedua model *PPSSVM* mempunyai nilai yang lebih kecil dibandingkan dengan kelompok data *testing* lainnya. Nilai *specificity* pada kelompok tersebut dibawah 80%. Sedangkan untuk kelompok data *testing* lainnya nilai *specificity* diatas 84%. Apabila dilihat dari rata-rata nilai *specificity*, maka model *PPSSVM1* mempunyai rata-rata nilai *specificity* tertinggi sebesar 85,85%.

Sebuah *classifier* yang baik umumnya memiliki *sensitivity* maupun *specificity* yang sama-sama tinggi. Ketiga metode yang digunakan dalam penelitian ini memenuhi hal tersebut pada kelompok data terpartisi 80:20 dengan nilai *sensitivity* dan *specificity* di atas 88%.

Tabel 4. Sensitivity dan Specitifty Klasifikasi SSVM, dan PPSSVM1 dan PPSSVM2

Evaluasi Performansi	Partisi	SSVM (%)	PPSSVM1 (%)	PPSSVM2 (%)
[1]	[2]	[3]	[4]	[5]
Akurasi	90:10	88.36	90.41	90.41
	80:20	88.05	89.07	89.08
	70:30	91.57	92.48	91.80
	60:40	90.78	91.46	91.30
	50:50	92.08	92.35	92.62
Rata-rata		90.17	91.15	91.04
Sensitivity	90:10	72.50	72.50	72.50
	80:20	88.81	88.81	89.44
	70:30	94.72	95.05	94.39
	60:40	95.63	95.86	96.09
	50:50	96.64	96.82	97.17
Rata-rata		89.66	89.81	89.92
Specificity	90:10	94.34	97.17	97.17
	80:20	87.12	89.39	88.64
	70:30	84.56	86.76	86.03
	60:40	76.82	78.81	77.48
	50:50	76.51	77.11	77.11
Rata-rata		83.87	85.85	85.29

Keterangan : Nilai-nilai yang dicetak tebal menunjukkan akurasi, *sensitivity*, *specificity* tertinggi pada setiap kelompok data.

Tabel 5. Luas Area di bawah kurva ROC Hasil Klasifikasi SSVM, dan PPSSVM1 dan PPSSVM2

Evaluasi Performansi	Partisi	SSVM	PPSSVM1	PPSSVM2
[1]	[2]	[3]	[4]	[5]
AUC	90:10	0.834	0.848	0.848
	80:20	0.880	0.891	0.890
	70:30	0.896	0.909	0.902
	60:40	0.862	0.873	0.868
	50:50	0.866	0.870	0.871
Rata-rata		0.868	0.878	0.876

Keterangan : Nilai-nilai yang dicetak tebal menunjukkan nilai *AUC* tertinggi pada setiap kelompok data.

Secara umum berdasarkan Tabel 5 kinerja metode *SSVM* diklasifikasikan sebagai ‘good’. Sedangkan pada metode *PPSSVM1* dan *PPSSVM2* klasifikasi kinerjanya adalah ‘exellent’ pada data terpartisi 70:10, pada partisi lainnya klasifikasi kinerjanya adalah ‘good’. Metode *PPSSVM1* pada dasarnya mempunyai performansi yang lebih baik dibandingkan dengan metode lainnya, hanya saja pada penelitian ini metode *PPSSVM1*

dan *PPSSVM2* dapat dikatakan sama baiknya dalam menentukan klasifikasi desa tertinggal di Provinsi Kalimantan Timur Tahun 2011. Hal tersebut dapat dilihat dari rata-rata nilai *AUC* pada metode *PPSSVM1* dan *PPSSVM2* yang relatif sama.

IV. KESIMPULAN DAN SARAN

Kesimpulan

1. Analisis secara teoritis menunjukkan bahwa performansi *piecewise polynomial function2* lebih baik dibandingkan dengan *piecewise polynomial function1*. Selain itu konvergensi metode *PPSSVM2* memberikan hasil yang lebih baik dibandingkan dengan *PPSSVM1*. Sehingga secara teoritis dapat disimpulkan bahwa metode *PPSSVM2* adalah metode terbaik.
2. Evaluasi performansi model klasifikasi dengan menggunakan nilai akurasi *sensitivity*, *spesitifity* dan nilai *AUC*. Berdasarkan pada penelitian ini metode *PPSSVM1* dan *PPSSVM2* dapat dikatakan sama baiknya untuk klasifikasi desa tertinggal di Provinsi Kalimantan Timur Tahun 2011. Hal tersebut dilihat dari rata-rata nilai *AUC* yang relatif sama. Berdasarkan nilai *AUC* secara umum metode *PPSSVM1* dan *PPSSVM2* mampu mengklasifikasikan desa tertinggal di Provinsi Kalimantan Timur Tahun 2011 dengan baik, atau dengan kata lain kinerja metode tersebut diklasifikasikan sebagai 'good'.

Saran

1. Pada penelitian berikutnya dapat mempertimbangkan untuk menambah variabel prediktor lebih banyak agar hasil yang dicapai menjadi lebih baik, misalnya variabel-variabel yang berhubungan dengan faktor alam/lingkungan, faktor kelembagaan, faktor sarana/prasarana, dan faktor sosial ekonomi penduduk yang belum digunakan dalam penelitian ini.
2. Pada penelitian ini kasus yang digunakan adalah desa tertinggal di Provinsi Kalimantan Timur Tahun 2011. Hasil yang diperoleh menunjukkan bahwa metode *PPSSVM2* cenderung tidak bisa meningkatkan performansi secara signifikan dan

hasilnya tidak dapat disimpulkan secara *general*. Untuk itu dalam penelitian selanjutnya dapat digunakan data simulasi.

DAFTAR PUSTAKA

- Agresti, A. (2006), *An Introduction to Categorical Data Analysis 2nd Ed*, John Wiley & Sons: New Jersey.
- Anguita, D., Ghelardoni, L., dan Ghio, A., (2012). The ‘K’ in K-fold Cross Validation. *ESANN 2012 proceedings, European Symposium on Artificial Neural Network, Computational Intelligence and Machine Learning. Bruges (Belgium)*.
- Bertsimas, D. dan Shioda, R. (2007), Clasification and Regression Via Integer Optimazion, *Journal of Operation Research*, Vol 55, No.2, hal 252-271.
- Dirjen Pemberdayaan Masyarakat Desa (PMD) Kemendagri, (2012), *Profil Desa dan Kelurahan 2011: Data Dasar Tipologi, Klasifikasi, Kategori Desa dan Kelurahan Menurut Provinsi*, Dirjen PMD Kemendagri, Jakarta.
- Faraggi, D., dan Reiser, B. (2002), Estimation of The Area Under The ROC Curve, *Journal of Statistics in Medicie*, Vol. 21, hal 3093-3106.
- Huang, C.M., Lee, Y.J., Lin D.K.J., dan Huang, S.Y. (2007), Model selection for support vector machine via uniform design, *Computational Statistics and Data Analysis*, Vol. 52. hal. 335-346.
- Hsu, C.W., Chang, C. C., dan Lin, C. J. (2008). A practical guide to Support Vector Classification, Taipei: Information Engineering National Taiwan University.
- Kohavi, R. (1995), A Study of Cross-Validation and Bootstrap for Accuracy Estimation and Model Selection, *Appears in the International Joint Coference on Artificial Intelligence (IJCAI), 1995*.
- Lee, Y.J., dan Mangasarian, O.L. (2001), A Smooth Support Vector Machine, *Jurnal of Computational Optimization and Applications* 20:5-22.
- Luo, L., Lin, C., Peng, H. dan Zhou, Q. (2006), A Study on Piecewise Polynomial Smooth Approximation to The Plus Function, In Proceedings of The ICARCV.

- Mangasarian, O.L., dan Musicant, D.R. (1999), Succesive Overrelaxation for Support Vector Machines, *IEEE Transactions on Neural Network*, 10, hal. 1032 – 1037.
- Metz, C.E. (2006), Receiver Operating Characteristic Analysis: A Tool for the Quantative Evolution of Observer Performance and Imaging Systems, *Journal of Amerian College of Radiology*, Vol.3, hal. 413 – 422.
- Mohanty, A.K., Beberta, S., dan Lenka,S.K. (2011). Classifying Benign and Malignant Mass using GLCM and GLRLM based Texture Features form Mammogram, *International Journal of Engineering Research and Applications (IJERA)*, Vol.1, hal 687-693.
- Purnami, S.W., Embong, A., Zain, J.M., dan Rahayu, S.P. (2009a), A Comparison of Smoothing Function In Smooth Support Vector Machine, *Will Be Presented in International Conference on Software Engineering & Computer Systems*.
- Vapnik, V. (1995). *The Nature of Statistical Learning Theory*, Springer-Verlag, New York
- Wu, Q., dan Wen Qing, W. (2013). Piecewise-Smooth Support Vector Machine for Clasification,*Hindawi Publishing Corporation Matematical Problems in Engineerin*, Volume 2013, Article ID 135149.
- Yuan, Y., dan Huang, T. (2005). A Polynomial Smooth Support Vector Machine for Classification, *Springer-Verlag, Berlin Heidelberg*, LNAI 3584: 157-164.
- , Yan J., dan Xu, C. (2005), Polynomial Smooth Support Vector Machine (PSSVM), *Chinese Journal of Computers*,28: 9-17.