

**KLASIFIKASI INDEKS PEMBANGUNAN MANUSIA
KABUPATEN/KOTA SE-INDONESIA
DENGAN PENDEKATAN *SMOOTH SUPPORT VECTOR MACHINE* (SSVM)
KERNEL RADIAL BASIS FUNCTION (RBF)**

Fatkurokhman Fauzi¹, Moh. Yamin Darsyah² dan Tiani Wahyu Utami³
^{1,2,3}FMIPA, Universitas Muhammadiyah Semarang, Semarang, Indonesia
(E-mail: fatkurokhmanfauzi@gmail.com)

Abstract

Human Development Index (HDI) is a measure of human development achievement based on basic components of quality of life. The human development index is low if the HDI is less than 60, moderate HDI between 60 to less than 70, high HDI between 70 to less than 80, and equal to 80 and more than 80 are high. Smooth Support Vector Machine (SSVM) is a classification technique that is new. The algorithm used is Radial Basis Function (RBF). The result of human development sperm using SSVM method with RBF kernel is 100%. With 41 districts / cities including low HDI. While 332 districts / cities are included in medium HDI coverage, 134 districts / cities are included in the high HDI, and 12 districts / cities including HDI is very high.

Keywords : *Human Development Index, Smooth Support Vector Machine (SSVM), Radial Basis Function (RBF), accuracy, classification.*

1. PENDAHULUAN

Indeks Pembangunan Manusia (IPM) atau *Human Devlopment Index* (HDI) merupakan indeks pembangunan manusia yang dipergunakan untuk pencapaian hasil dari pembangunan suatu daerah atau wilayah dalam tiga dimensi dasar pembangunan yaitu lamanya hidup, pengetahuan/tingkat pendidikan, dan standar hidup layak. Untuk mengukur dimensi kesehatan, digunakan angka harapan hidup waktu lahir. Angka harapan hidup merupakan tolak ukur kualitas kesehatan di daerah tersebut. Selanjutnya untuk mengukur dimensi pengetahuan digunakan gabungan indikator harapan lama sekolah dan rata-rata lama sekolah. Adapun untuk mengukur dimensi hidup layak digunakan indikator kemampuan daya beli masyarakat terhadap sejumlah kebutuhan pokok yang dilihat dari rata-rata besarnya pengeluaran per kapita disesuaikan. Klasifikasi Indeks pembangunan manusia menurut (BPS, 2014) dikatakan rendah jika $IPM < 60$, sedang $60 \leq IPM < 70$, tinggi $70 \leq IPM < 80$, dan ≥ 80 sangat tinggi.

Support Vector Machine (SVM) adalah suatu teknik yang relatif baru pada tahun 1995 untuk melakukan prediksi, baik dalam kasus klasifikasi maupun regresi, yang sangat populer belakangan ini. Menurut (Wu & Fan, 2013) SVM adalah solusi global optimal dan menghindari *deminsionality*. Dalam melakukan prediksi SVM diketahui sangatlah akurat dengan tingkat keakuratan mencapai 90%, hal ini dibuktikan oleh (Pristiyani *et al*, 2016) yang berjudul "Performansi Perusahaan Finansial Distress dengan Metode Support Vector Machine" dan (Darsyah, 2014) dengan judul "Klasifikasi Tuberkulosis Dengan Pendekatan Metode Supports Vector Machine (SVM)". Namun SVM dalam melakukan prediksi dengan datanya besar tidak efisien. Oleh karena itu dikembangkan metode *smooth technique* yang

mengganti *plus function* SVM dengan integral fungsi *sigmoid neural network* yang selanjutnya dikenal dengan *Smooth Support Vector Machine* (SSVM). Keakuratan SSVM hampir mencapai 100% jika datanya tidak lebih dari 3000, hal ini dibuktikan dalam jurnal yang ditulis oleh (Suryanto& Purnami, 2015)dengan judul “Perbandingan *Reduced Support Vector Machine* dan *Smooth Vector Machine* untuk Klasifikasi *Large Data*”. Kesimpulan yang didapat dari penelitian yang dilakukan bahwa metode SSVM sangat akurat digunakan untuk kasifikasi dengan tingkat akurasi 100% untuk SSVM tipe linier, 99.83 % untuk tipe lingkaran dan 99.93% tipe Checker-board. Sedangkan penelitian yang dilakukan (Lee & Mangasarian, 2001)yang di tuangkan dalam “SSVM: A Smooth Support Vector Machine for Classification”, menunjukkan bahwa metode SSVM sangatlah akurat untuk jumlah data yang besar. Sedangkan penelitian tentang Indeks Pembangunan Manusia (IPM) dilakukan oleh (Daarsyah & Wasono, 2013)dengan judul “Pendugaan IPM pada Area Kecil Di Kota Semarang dengan Pendekatan Non parametrik”.

Kernel Radial Basis Function (RBF) adalah suatu kernel yang sering digunakan dalam pengklasifikasian pada umumnya dan seringkali menghasilkan akurasi klasifikasi yang tinggi bahkan mencapai 100%. Hal ini diperkuat oleh penelitian yang telah dilakukan oleh (Darsyah, 2013) dengan judul ” Menakar Tingkat Akurasi Support Vector Machine Study Kasus Kanker Payudara” pada penelitian ini kernel RBF mampu mengasilkan akurasi yang tinggi.

Dari kedua penelitian tentang *Smooth Support Vector Machine*(SSVM), serta penelitian tentang keakuratan yang ditunjukkan oleh kernel RBF, maka dalam penelitian ini akan menggunakan meotde SSVM dengan kernel RBF untuk pengklasifikasian Indeks Pembangunan Manusia Kabupaten/Kota se-Indonesia.

Tujuan dari penelitian ini adalah untuk mengetahui prediksi dan akurasi hasil prediksi, serta hasil klasifikasi IPM dengan metode SSVM menggunakan kernel RBF. Dalam penelitian ini menggunakan algoritma Newton Armijo.

2. KAJIAN LITERATUR

a. *Smooth Support Vector Machine* (SSVM)

Smooth Support Vector Machine (SSVM) pengembangan dari metode *Support Vector Machine*(SVM). Tujuan dari SVM maupun SSVM adalah sama yaitu menemukan fungsi pemisah (*hyperplane*) yang optimal sebagai pemisah dua buah kelas atau lebih pada *input space*. *Hyperplane* terbaik adalah memiliki garis yang maksimal yang memisahkan kedua kelompok. Perbedaan mendasar SVM dengan SSVM adalah pada SSVM melibatkan fungsi *smoothing* didalamnya. Jika terpadat masalah dari klasifikasi titik m di dalam n ruang dimensi nyata R^n , bentuk dari dari matriks $m \times n$ adalah matrik A , Anggota dari titik A_i di dalam kelas $+1$ atau -1 didefinisikan untuk matriks diagonal $Dm \times m$ dengan diagonal $+1$ atau -1 . Untuk masalah SVM dengan sebuah *kernel* linier AA' diberikan untuk $v > 0$:

$$\begin{aligned} \min_{(w,\gamma,y) \in R^{n+1+m}} \quad & ve'y + \frac{1}{2}w'w \\ \text{s.t} \quad & d(A\omega - e\gamma) + y \geq e \\ & y \geq 0 \end{aligned} \tag{1}$$

Dimana wadalah normal untuk *bounding planes*:


$$\begin{aligned} x'w - \gamma &= +1 \\ x'w - \gamma &= -1 \end{aligned} \tag{2}$$

Dan γ menentukan daerah *relative* asal. Garis pemisah pertama (*margin*) batasnya adalah $+1$ dan garis pemisah kedua (*margin*) batasnya adalah -1 ketika kedua kelas dipisahkan secara *linier*, yaitu ketika variabel *slacky* = 0. Garis pemisah linier ketika:

$$x'w = \gamma \quad (3)$$

Batasan tengah antara dua garis (lihat gambar 1). Jika kelas linier tidak bisa dipisahkan kemudian dua palne membatasi dua kelas dengan "soft margin" ditentukan oleh variabel *slack y nonnegatif*, yaitu:

$$\begin{aligned} x' - \gamma + y_i &\geq +1 \text{ untuk } x' = A_i \text{ dan } D_{ii} = +1 \\ x' - \gamma - y_i &\leq +1 \text{ untuk } x' = A_i \text{ dan } D_{ii} = -1 \end{aligned} \quad (4)$$



Gambar 1. kedua garis pembatas dengan margin $\frac{2}{\|w\|_2}$ dan garis ke-3 memisahkan A +, titik tersebut mewakili dari baris A dengan $D_{ii} = +1$. Dari A -, titik tersebut mewakili A dengan $D_{ii} = -1$.

Peraturan pertama dari variabel *slack y* adalah meminimalisasi dengan pembobot v dalam persamaan (1). pembatas kedua garis dengan margin $\frac{2}{\|w\|_2}$, dan pemisah garis 3 yang memisahkan A +, mewakili titik dari baris A dengan $D_{ii} = 1$, dari A -, mewakili titik dari baris A dengan $D_{ii} = -1$.

$$\begin{aligned} \min_{\omega, \gamma, y} & \frac{v}{2} y' y + \frac{1}{2} (w + \gamma^2) \\ \text{s. t } & D(Aw - e\gamma) + y \geq e \\ & y \geq 0 \end{aligned} \quad (5)$$

Solusi dari permasalahan di atas adalah

$$y = (e - D(Aw - e\gamma))_+ \quad (6)$$

(.)+ diganti dengan komponen *negative* dari vektor nol, dengan demikian dapat mengganti y dalam persamaan (5) dengan $(e - D(Aw - e\gamma))_+$ dan mengubah masalah *Support Vector Machine* (SVM) pada persamaan (5) kedalam *Support Vector Machine*(SVM) yang merupakan masalah optimasi dibatasi sebagai berikut:

$$\min_{\omega, \gamma} \frac{v}{2} \|(e - D(Aw - e\gamma))_+\|_2^2 + \frac{1}{2} (\omega' \omega + \gamma^2) \quad (7)$$

Dimana pada (.)+ komponen yang bernilai *negative* digantikan dengan nilai nol. Persamaan 7 memiliki solusi yang unik tetapi fungsi objektif tidak memiliki fungsi turunan kedua (suryanto dan purnami, 2015). Lee dan Mangasarian (2001) mengusulkan *smooth technique* yang menggantikan (.)+ dengan integral dari fungsi *sigmoid neural network* (8) Damana α adalah parameter *smoothing*, sehingga diperoleh model SSVM sebagai berikut:

$$\begin{aligned} \min_{(\omega, \gamma) \in R^{n+1}} \Phi_{\alpha}(\omega, \gamma) \\ := \min_{(\omega, \gamma) \in R^{n+1}} \frac{\nu}{2} \|p(e - D(A\omega - e\gamma), \alpha)\|_2^2 + \frac{1}{2}(\omega' + \gamma^2). \end{aligned}$$

b. Smooth Support Vector Machine (SSVM) non-linier

Formulasi *Smooth Support Vector Machine* (SSVM) pada dasarnya adalah linier untuk masalah klasifikasi. Permasalahan muncul ketika kasus tidak linier. cara melinierkan kasus tidak linier dengan menggeneralisasi menggunakan kernel. Persamaan SSVM untuk kasus non linier sebagai berikut:

$$\min_{u, v} \frac{\nu}{2} \|p(e - D(k(A, A')Du - e\gamma), \alpha)\|_2^2 + \frac{1}{2}(u'u + \gamma^2) \quad (9)$$

Dimana $K(A, A')$ adalah sebuah kernel dari $R^{m \times n} \times R^{n \times m} R^{m \times m}$.

c. Algoritma Newton Armijo

Optimasi persamaan SSVM dapat diselesaikan dengan pendekatan algoritma newton Armijo yaitu menginisiasi $w^0, \gamma^0 \in R^{n+1}$ dimana $w^{(i)}$ menunjukkan iterasi. Selanjutnya mengulangi hingga didapat $\nabla\Phi_{\alpha}(w^i, \gamma^i) = 0$. Adapapun langkah langkah newton armijo sebagai berikut:

1. Petunjuk *Newton*: Petunjuk determinan $d^i \in R^{n+1}$ dengan keadaan linier dari $\nabla\Phi_{\alpha}(w, \gamma)$ di sekitar (w^i, γ^i) yang meberikan persamaan $n + 1$ linier di dalam $n + 1$ variabel:

$$\nabla^2\Phi_{\alpha}(w^i, \gamma^i)d^i = -\nabla\Phi_{\alpha}(w^i, \gamma^i)' \quad (10)$$

2. Langkah Armijo [1]: pilih sebuah langkah $\lambda_i \in R$ sedemikian

$$(w^{i+1}, \gamma^{i+1}) = (w^i, \gamma^i) + \lambda_i d^i \quad (11)$$

Dimana $\lambda_i = \max \left\{ 1, \frac{1}{2}, \frac{1}{4}, \dots \right\}$ sedemikian hingga:

$$\Phi_{\alpha}(w^i, \gamma^i) - \Phi_{\alpha}(w^i, \gamma^i) + \Phi_{\alpha}((w^i, \gamma^i) + \lambda_i d^i) \geq -\delta \lambda_i \Phi_{\alpha}(w^i, \gamma^i) d^i \quad (12)$$

Dimana $\delta \in (0, \frac{1}{2})$

d. Kernel Radial Basis Function (RBF)

Model yang umum digunakan untuk menyelesaikan masalah klasifikasi dan regresi adalah model linier. Namun dalam kenyataana data dalam dunia nyata banyak yang tidak berbentuk/menyerupai model liner. Penggunaan fungsi kernel sebagai fungsi basis adalah salah satu pendekatan yang digunakan untuk mengatasi data yang tidak linier.

Kernel RBF merupakan kernel yang banyak digunakan dalam kasus klasifikasi. Adapun rumus kernel RBF adalah sebagai berikut (Prasetyo, 2012):

$$K(x, y) = \exp\left(\frac{-\|x - y\|^2}{2 \cdot \sigma^2}\right) \quad (13)$$

e. K-fold cross validation (KCV)

K-fold cross validation merupaka teknik untuk membagi dokumen menjadi k bagian. Pembagian tersebut merupakan pembagian sebagi data *training* dan *test set*. Seluruh data secara acak dibagi menjadi K buah subset B_k dengan ukuran yang sama dimana himpunan bagian dari $\{1, \dots, n\}$, sedemikian sehingga $\cup_{k=1}^K B_k = \{1, \dots, n\}$ dan $B_j \cap B_k = \emptyset (j \neq k)$. Kemudian dilakukan tahap iterasi sebanyak k kali, kemudian pada iterasi ke k subset B_k menjadi *test test* sedangkan sisanya menjadi *training set*. Kelebihan dari metode *k-fold cros validation* adalah tidak adanya permasalahan dalam pembagian data.

f. Pengukuran Kinerja Klasifikasi

Diharapkan dalam suatu klasifikasi semua data dapat diklasifikasi dengan benar, tetapi terkadang tidak bisadiga klasifikasi yang didapat tidak mencapai 100% benar sehingga sebuah sistem klasifikasi juga harus diukur kinerjanya. Dalam pengukuran kinerja klasifikasi umumnya dilakukan dengan matriks konfusi (*confusion matrix*).

Tabel 1. Matriks Konfusi untuk Dua Kelas (Prasetyo, 2012)

f_{ij}		Kelas hasil prediksi(j)	
		Kelas 0	Kelas 1
Kelas asli(i)	Kelas 1	f_{11}	f_{10}
	Kelas 0	f_{01}	f_{00}

Berdasarkan isian dari matriks konfusi dapat dihitung jumlah data yang benar dan jumlah data yang salah. Kuantitas matriks konfusi dapat dihitung akurasi dan laju *error*. Setelah mengetahui jumlah klasifikasi yang benar, dapat diketahui akurasi hasil prediksi. Sedangkan untuk hasil klasifikasi yang salah dapat kita hitung laju *error* dari prediksi yang dilakukan. Akurasi dan laju *error* digunakan sebagai tolak ukur kinerja klasifikasi.

Untuk menghitung hasil laju *error* dan akurasi menggunakan formula (Prasetyo, 2012)

$$Akurasi = \frac{\text{jumlah data yang diprediksi secara benar}}{\text{jumlah prediksi yang dilakukan}} \times 100\% \quad (14)$$

$$\text{Laju error} = \frac{\text{jumlah data yang dipredisi secara salah}}{\text{jumlah prediksi yang dilakukan}} \times 100\% \quad (15)$$

3. METODE PENELITIAN

a. Sumber Data dan Variabel Penelitian

Data yang digunakan dalam penelitian ini adalah data sekunder dari Badan Pusat Statistik (BPS). Data yang diambil adalah data tentang indeks pembangunan manusia, rata-rata lama sekolah, harapan lama sekolah, angka harapan hidup, dan pengeluaran perkapita yang disesuaikan tahun 2015. Jumlah data yang diteliti 519 data tiap variabel, yang dimana 519 adalah jumlah kabupaten/kota se-Indonesia.

Variabel Penelitian merupakan istilah yang sangat populer dalam melakukan penelitian. Dalam sebuah penelitian, umumnya memiliki 2 jenis variabel yaitu variabel respon dan variabel prediktor.

Variabel penelitian yang digunakan dalam penelitian ini adalah Indeks Pembangunan Manusia (IPM) sebagai variabel respon serta angka harapan hidup, rata-rata lama sekolah, harapan lama sekolah dan pengeluaran perkapita yang disesuaikan sebagai variabel prediktor merujuk pada penelitian Moh Yamin Darsyah dan Rochdi Wasono (2013). Variabel dalam penelitian ini terdiri atas dua bagian yaitu variabel respon (Y) dan variabel prediktor (X). Variabel Respon terdiri dari empat kategori yaitu:

- Y= 1 untuk indeks pembangunan manusia rendah
- Y= 2 untuk indeks pembangunan manusia sedang
- Y= 3 untuk indeks pembangunan manusia tinggi
- Y= 4 untuk indeks pembangunan manusia sangat tinggi

b. Langkah Analisis yang Digunakan

Tahapan analisis yang akan digunakan untuk mencapai tujuan dari penelitian ini adalah:

1. Melakukan pengumpulan data sekunder, yaitu indeks pembangunan manusia, angka harapan hidup, rata-rata lama sekolah, harapan lama sekolah, dan pengeluaran perkapita yang disesuaikan.
2. Statistik deskriptif Indeks Pembangunan Manusia (IPM) kabupaten/kota se-Indonesia tahun 2015.
3. Melakukan klasifikasi indeks pembangunan manusia dengan metode SSVM. Berikut algoritma metode SSVM:
 - a. Membentuk data *training* dan *testing* untuk setiap dataset.
 - b. Menentukan parameter SSVM menggunakan Algoritma Newton Armijo.
 - c. Membangun model SSVM menggunakan fungsi kernel RBF.
 - d. Menentukan hasil prediksi yang benar dan yang salah dengan tabel kontingensi pada kernel RBF.
 - e. Menghitung akurasi dari prediksi yang terbentuk dengan cara membagi jumlah prediksi yang benar dengan jumlah data, serta mengetahui hasil klasifikasi yang terbentuk.
4. Membuat kesimpulan dan saran atas hasil yang diperoleh dari penelitian.

4. HASIL PENELITIAN

a. Statistik Deskriptif

Statistik merupakan metode yang berkaitan dengan pengumpulan dan penyajian suatu gugus data sehingga memberikan informasi yang berguna. Statistik deskriptif bertujuan untuk mengetahui gambaran umum data. Hasil uji statistik deskriptif indeks pembangunan manusia

Tabel 2. Statistik Deskriptif

	N	Minimum	Maximum	Mean	Std. Deviation
IPM	519	25.47	84.56	67.1019	6.85551
AHH	519	53.60	77.46	68.7497	3.67270
HLS	519	2.17	17.01	12.4215	1.42082
RLS	519	.64	12.38	7.7935	1.68445
Perkapita	519	3625.36	22424.62	9397.3566	2558.65485
Valid N (listwise)	519				

beserta faktor-faktor yang mempengaruhinya diantaranya angka harapan hidup, harapan lama sekolah, rata-rata lama sekolah, dan pengeluaran perkapita yang disesuaikan terdapat pada tabel 2.

Berdasarkan tabel 2 jumlah sampel masing-masing variabel adalah 519 yang merupakan kabupaten/kota se-Indonesia pada tahun 2015. Untuk penjelasan terperinci mengenai statistik deskriptif tiap variabel sebagai berikut:

1) Indeks Pembangunan Manusia (IPM)

Dari hasil pengujian statistik deskriptif tabel 2 bahwa rata-rata indeks pembangunan manusia seluruh kabupaten/kota se-Indonesia adalah 67.1019 dimana dalam pengklasifikasian yang dilakukan oleh BPS termasuk dalam golongan IPM sedang. IPM tertinggi adalah 84.56 yaitu Kota Yogyakarta dan terendah adalah 25.47 yaitu Kabupaten Nduga, dengan standar deviasi sebesar 6.85551.

2) Angka Harapan Hidup (AHH)

Angka harapan hidup menggambarkan kualitas kesehatan masyarakat disuatu daerah. Angka harapan hidup juga merupakan rata-rata lama umur atau masa hidup di suatu daerah. Berdsarkan hasil pengujian statistik deskriptif tabel 2 diketahui bahwa rata-rata angka harapan hidup kabupaten/kota se-Indonesia adalah 68.749, artinya bahwa rata-rata lama umur atau masa hidup di kabupaten/kota se-Indonesia adalah berkisar 68 tahun. Untuk angka harapan hidup tertinggi adalah 77.46 yaitu Kabupaten Sukoharjo dan terendah adalah 53.60 yaitu Kabupaten Nuga, dengan standar deviasi sebesar 3.67270

3) Harapan Lama Sekolah (HLS)

Harapan lama sekolah merupakan lamanya sekolah yang diharapkan akan dirasakan oleh anak pada umur tertentu pada masa yang akan datang. Berdsarkan tabel 2 rata-rata harapan lama sekolah kabupaten/kota se-Indonesia tahun 2015 sebesar 12.4215, artinya harapan lama sekolah yang akan dirasakan oleh anak dimasa mendatang berkisar 12 tahun. Harapan lama sekolah tertinggi adalah 17.01 yaitu Kota Banda Aceh dan terendah adalah 2.17 yaitu Kabupaten Nduga, sedangkan setandar defiasinya adalah 1.42082.

4) Rata-rata Sekolah(RLS)

Rata-rata lama sekolah menggambarkan jumlah yang digunakan oleh masyarakat dalam menjalani Pendidikan formal. Berdsarkan tabel 1 rata-rata lama sekolah kabupaten/kota se-Indonsia tahun 2015 sebesar 7.7935, artinya jumlah yang digunkan masyarakat dalam menempuh Pendidikan formal adalah 7 tahun. Rata-rata lama sekolah tertinggi 12.38 yaitu Kota Banda Aceh dan terendah adalah 0.64 yaitu Kabupaten Nduga, dengan standar deviasi 1.68445.

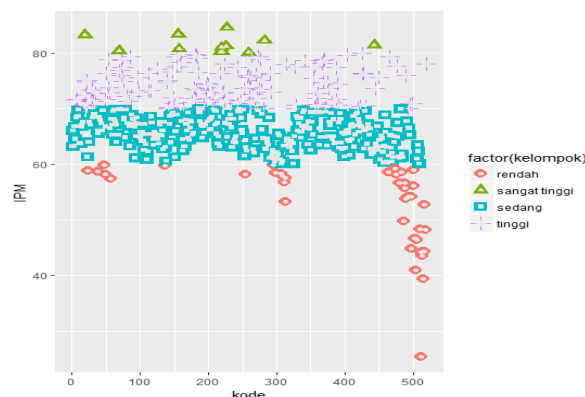
5) Pengeluaran perkapita yang disesuaikan

Pengeluaran perkapita didapat dari dimensi standar hidup layak yaitu menggambarkan tingkat kesejahteraan. Berdsarkan tabel 2 rata-rata pengeluaran perkapita yang disesuaikan adalah 9397.3566, dengan pengeluaran perkapita yang tertinggi sebesar 22424.62 yaitu Kota Jakarta Selatan dan terendah 3625.36 yaitu Kabupaten Nduga. Standar deviasi pengeluaran perkapita yang disesuaikan sebesar 2558.65485.



Gambar 2. Klasifikasi IPM

Berdsarkan gambar 1sebanyak 322 kabupaten/kota tergolong dalam IPM sedang, 134 kabupaten/kota tinggi, 41 kabupaten/kota rendah, dan 12 kabupaten/kota dengan IPM tinggi.



Gambar 3. Persebaran IPM

Berdasarkan gambar 3 persebaran IPM dengan kategori sedang dan tinggi tersebar merata diseluruh Indonesia. Sedangkan untuk IPM rendah dan tinggi tidak tersebar merata di kabupaten/kota Indonesia, serta jumlahnya sedikit.

b. Prediksi dan Akurasi Prediksi Klasifikasi Indeks Pembangunan Manusia (IPM) dengan *Smooth Support Vector Machine* (SSVM) kernel Radial Basis Function (RBF)

Klasifikasi Indeks Pembangunan Manusia (IPM) kabupaten/kota se-Indonesia tahun 2015 menggunakan pendekatan kernel RBF terangkum dalam tabel kontingensi 3.

Berdasarkan tabel 3 IPM kelompok rendah (satu) diprediksi secara benar berjumlah 41, kelompok sedang (dua) sejumlah 322, kelompok tinggi (tiga) sejumlah 132, dan kelompok sangat tinggi (empat) sejumlah 12. Tidak ada satupun IPM diprediksi secara salah.

$$\begin{aligned}
 \text{Akurasi} &= \frac{\text{jumlah data yang diprediksi secara benar}}{\text{jumlah prediksi yang dilakukan}} \times 100\% \\
 &= \frac{519}{519} \times 100\%
 \end{aligned}$$

Tabel 3. Kontingensi SSVM Kernel Radial Basis Function(RBF)

f_{ij}		Kelas hasil prediksi(j)			
		Kelas = 1	Kelas = 2	Kelas =3	Kelas = 4
Kelas asli(i)	Kelas = 1	41	0	0	0
	Kelas = 2	0	322	0	0
	Kelas = 3	0	0	134	0
	Kelas = 4	0	0	0	12

$$= 100\%$$

Akurasi klasifikasi Indeks pembangunan Manusia(IPM) kabupaten/kota se-Indonesia tahun 2015 dengan *Smooth Support Vector Machine (SSVM)* kernel Radial Basis Function (RBF) sebesar 100%.

c. Klasifikasi Indeks Pembangunan Manusia(IPM) Kabupaten/Kota se-Indonesia menggunakan Metode *Smooth Support Vector Machine(SSVM)*Kernel RBF

Berdasarkan tabel peringkasan output pada tabel kontingensi 3 terdapat 519 kabupaten/kota dengan klasifikasi yang tepat. Terdapat 41 kabupaten/ kota dengan klasifikasi IPM rendah diantaranya Kabupaten Nias, Kabupaten Nias Selatan, Kabupaten Nias Utara, Kabupaten Nias Barat, Kabupaten Kepulauan Mentawai, Kabupaten Mesuji, Kabupaten Sampang, Kabupaten Timor Tengah Selatan, dan Kabupaten Alor. IPM dengan klasifikasi sedang terdapat 332 kabupaten/kota diantaranya Kabupaten Aceh Utara, Kabupaten Aceh Barat Daya, Kabupaten Lues, Kabupaten Aceh Taming, Kabupaten Aceh Jaya, Kabupaten Aceh Singkil, Kabupaten Aceh Selatan, Kabupaten Aceh Tenggara, Kabupaten Aceh Barat, dan Kabupaten Pidie. Klasifikasi IPM tinggi terdapat 134 kabupaten/kota yaitu Kabupaten Aceh Besar, Kabupaten Bener Meriah, Kabupaten Pidie Jaya, Kota Sabang, Kota Langsa, Kota Lhokseumawe, Kabupaten tapanuli Utara, dan Kabupaten Karo. Sedangkan IPM tinggi sebanyak 12 kabupaten/kota diantaranya Kota Banda Aceh, Kota Padang, Kota Jakarta Selatan, Kota Jakarta Timur, Kota Surakarta, Kota Salatiga, Kota Semarang, Kabupaten Sleman, Kota Yogyakarta, Kota Malang, Kota Denpasar, dan Kota Kendari.

5. SIMPULAN

Kesimpulan dari penelitian ini adalah:

1. Prediksi Indeks Pembangunan Manusia (IPM) kabupaten/kota se-Indonesia tahun 2015 dengan metode *Smooth Support Vector Machine (SSVM)* kernel RBF memberikan hasil prediksi IPM rendah secara benar berjumlah 41, sedang 332, tinggi 134, dan sangat tinggi 12. Jumlah keseluruhan kelompok yang diprediksi secara benar adalah 519 dengan tingkat akurasi prediksi SSVM dengan kernel RBF sebesar 100%.
2. Klasifikasi Indeks Pembangunan Manusia (IPM) dengan metode *SmoothSupport Vector Machine (SSVM)* dengan kernel RBF didapat 41 kabupaten/kota yang termasuk IPM rendah. Sedangkan 332 kabupaten/kota termasuk dalam klasifikasi IPM sedang, 134 kabupaten/kota termasuk dalam klasifikasi IPM tinggi, dan 12 kabupaten/kota termasuk klasifikasi IPM sangat tinggi.

6. REFERENSI

BPS. (2014).*IndeksPembangunan Manusia Metode Baru*, Jakarta: BPS.

Darsyah, M.Y. (2013). Menakar Tingkat Akurasi Support Vector Machine Study Kasus Kanker Payudara. *Jurnal Statistika Unimus*,1(1), 15-20.

Darsyah, M.Y. (2014). Klasifikasi Tuberkulosis Dengan Pendekatan Metode Supports Vector Machine (SVM). *Jurnal Statistika Unimus*,2(2), 37-41.

- Darsyah, M.Y., & Wasono, R. (2013). Pendugaan IPM Pada Area Kecil Di Kota Semarang dengan Pendekatan Nonparametrik. *Prosiding 10th Seminar Nasional Statistika Universitas Diponegoro 2013*, 205-215.
- Lee, Y. J., & Mangasarian, O. L. (2001). SSVM: A Smooth Support Vector Machine for Classification. *Computational Optimization and Applications*, 20(5), 5–22
- Prasetyo, E. (2012). *Data Mining Konsep dan Aplikasi Menggunakan MATLAB*. Yogyakarta: Andi
- Pristiyani, Darsyah, M.Y., & Nur, I.M. (2016). Performansi Perusahaan Finansial Distress Dengan Metode Support Vector Machine (SVM). *Jurnal Statistik Unimus*, 4(1), 20-29.
- Suryanto, E., & Purnami, S.W. (2015). Perbandingan Reduced Support Vector Machine dan Smooth Support Vector Machine untuk Klasifikasi Large Data. *Jurnal SAINS Dan SENI ITS*, 4(1), 25–30.
- Wu, Q., & Fan, J. L. (2013). Smooth support vector machine based on piecewise function. *Journal of China Universities of Posts and Telecommunications*, 20(5), 122–128.