


SVM untuk Regresi

Dr. rer. nat. Hendri Murfi

Intelligent Data Analysis (IDA) Group
Departemen Matematika, Universitas Indonesia – Depok 16424

Telp. +62-21-7862719/7863439, Fax. +62-21-7863439, Email. hendri@ui.ac.id

Machine Learning



- *Preprocessing*: ekstraksi fitur dan representasi data, misal dalam bentuk vektor $\mathbf{x}_i = (x_1, x_2, \dots, x_D)^T$
- *Learning*: pemilihan model dan penentuan parameter model, misal \mathbf{w} , berdasarkan data pelatihan (*training data*)
- *Testing*: pengujian metode dengan data pengujian (*testing data*) yang tidak sama dengan data pelatihan, sehingga didapat nilai estimasi untuk kapabilitas generalisasi dari model.

Learning



Diberikan data pelatihan $\mathbf{x}_i, i = 1 \text{ sd } N$, dan/atau $\mathbf{t}_i, i = 1 \text{ sd } N$

- **Supervised Learning.** Data pelatihan disertai target, yaitu $\{\mathbf{x}_i, \mathbf{t}_i\}, i = 1 \text{ sd } N$. Tujuan pembelajaran adalah membangun model yang dapat menghasilkan output yang benar untuk suatu data input, misal untuk regresi, klasifikasi, regresi ordinal, ranking, dll
- **Unsupervised Learning.** Data pelatihan tidak disertai target, yaitu $\mathbf{x}_i, i = 1 \text{ sd } N$. Tujuan pembelajaran adalah membangun model yang dapat menemukan komponen/variabel/fitur tersembunyi pada data pelatihan, yang dapat digunakan untuk: pengelompokan (*clustering*), reduksi dimensi (*dimension reduction*), rekomendasi, dll

3

Supervised Learning

- **Regresi**
 - Nilai output \mathbf{t}_i bernilai kontinu (riil)
 - Bertujuan memprediksi output dari data baru dengan akurat
- **Klasifikasi**
 - Nilai output \mathbf{t}_i bernilai diskrit (kelas)
 - Bertujuan mengklasifikasi data baru dengan akurat



4

Model Linear

- Model yang umum digunakan untuk menyelesaikan masalah klasifikasi dan regresi adalah model linear, yaitu model yang merupakan kombinasi linear dari fungsi basis:

$$y(\mathbf{x}, \mathbf{w}) = \sum_{j=0}^{M-1} w_j \phi_j(\mathbf{x}) = \mathbf{w}^T \boldsymbol{\phi}(\mathbf{x})$$

Dimana $\mathbf{x} = (x_1, x_2, \dots, x_D)^T$ adalah variabel input, dan $\mathbf{w} = (w_0, w_1, \dots, w_D)^T$ adalah parameter, $\boldsymbol{\phi}(\mathbf{x})$ adalah *fungsi basis*, M adalah jumlah total parameter dari model

- Biasanya, $\phi_0(\mathbf{x}) = 1$, sehingga w_0 berfungsi sebagai bias
- Ada banyak pilihan yang mungkin untuk fungsi basis $\boldsymbol{\phi}(\mathbf{x})$, misal fungsi linear, fungsi polinomial, fungsi gaussian, fungsi sigmoidal, dll

5

Model Linear

Kutukan Dimensi

- Model linear memiliki sifat-sifat yang penting baik dari aspek komputasi maupun analitik. Penggunaan model linear dengan pendekatan parametrik pada metode klasik memiliki keterbatasan pada aplikasi praktis disebabkan oleh kutukan dimensi (*curse of dimensionality*)

$$y(x, w) = w_0 + w_1 x + w_2 x^2 + w_3 x^3$$

$$y(\mathbf{x}, \mathbf{w}) = w_0 + \sum_{i=1}^D w_i x_i + \sum_{i=1}^D \sum_{j=1}^D w_{ij} x_i x_j + \sum_{i=1}^D \sum_{j=1}^D \sum_{k=1}^D w_{ijk} x_i x_j x_k$$

1

D^3

untuk model beorde M , maka pertumbuhan jumlah parameter w proposional dengan D^M

6

Model Linear

Pendekatan Alternatif

- Pendekatan alternatif adalah membuat fungsi basis adaptif terhadap data pelatihan dengan jumlah fungsi basis ditentukan didepan.
- Dengan kata lain, menggunakan bentuk **parametrik tidak linear** dimana nilai-nilai parameter adaptif terhadap data pelatihan selama proses training.
- Contoh metode yang menggunakan pendekatan ini adalah *neural networks* (NN).

7

Model Linear

Pendekatan Nonparametrik

- Pendekatan lain adalah pendekatan nonparametrik, yaitu menetapkan data pelatihan sebagai pusat-pusat fungsi basis. Selanjutnya, memilih sebagian dari fungsi-fungsi basis tersebut selama proses pelatihan untuk menjadi fungsi-fungsi basis dari model final.
- Dasarnya adalah bahwa data real biasanya memiliki sifat mulus, artinya perubahan sedikit pada data input hanya akan memberikan sedikit perubahan pada output
- Fungsi basis yang banyak digunakan pada pendekatan nonparametrik ini adalah fungsi kernel.

8

Metode Kernel

Fungsi Kernel : Definisi

- Fungsi kernel adalah suatu fungsi k yang mana untuk semua vektor input \mathbf{x}, \mathbf{z} akan memenuhi kondisi

$$k(\mathbf{x}, \mathbf{z}) = \phi(\mathbf{x})^T \phi(\mathbf{z})$$

dimana $\phi(\cdot)$ adalah fungsi pemetaan dari ruang input ke ruang fitur

- Dengan kata lain, fungsi kernel adalah fungsi perkalian dalam (*inner product*) pada ruang fitur.

9

Metode Kernel

Fungsi Kernel : Contoh


- Salah satu contoh fungsi kernel yang banyak digunakan adalah *Gaussian radial basis function* (RBF), yaitu:

$$k(\mathbf{x}, \mathbf{x}') = \phi(\|\mathbf{x} - \mathbf{x}'\|) = \exp(-\|\mathbf{x} - \mathbf{x}'\|^2 / 2s^2)$$

dimana \mathbf{x}' adalah „inti“ yang dipilih dari data pelatihan.

- Contoh: fungsi basis dengan pusat/inti $\mathbf{x}' = 5$ dan bobot $w = 0.04$ dapat digambarkan sbb:


$$\begin{aligned} w * k(x, 5) &= 0.04 * \phi(\|x - 5\|) \\ &= 0.04 * \exp(-\|x - 5\|^2 / 2s^2) \end{aligned}$$



10

Metode Kernel

Fungsi Kernel : Keuntungan



- Fungsi kernel memungkinkan kita untuk mengimplementasikan suatu model pada ruang dimensi lebih tinggi (ruang fitur) tanpa harus mendefinisikan fungsi pemetaan dari ruang input ke ruang fitur
- Sehingga, untuk kasus yang *non-linearly separable* pada ruang input, diharapkan akan menjadi *linearly separable* pada ruang fitur
- Selanjutnya, kita dapat menggunakan *hyperplane* sebagai *decision boundary* secara efisien

11

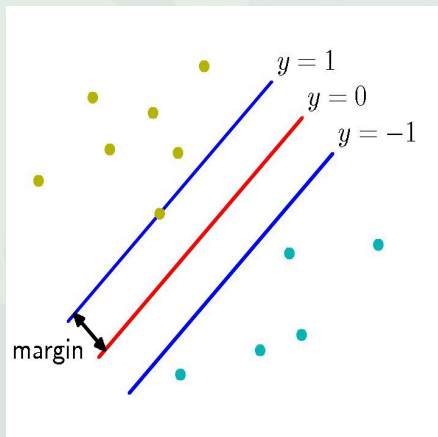
Metode Kernel

Fungsi Kernel : Penggunaan

- Secara umum, ada dua cara penggunaan metode kernel pada *machine learning*, yaitu:
 - Penggunaan langsung, yaitu fungsi kernel digunakan sebagai fungsi basis dari model machine learning tersebut, contoh: *radial basis function networks*
 - Penggunaan tidak langsung melalui *kernel trick*, yaitu merepresentasikan suatu model kedalam representasi dual yang mengandung *inner product* dari fungsi pemetaan, contoh: *kernel linear regression*, *kernel Perceptron*, ***support vector machine***, dll

Support Vector Machine

Maximum Margin

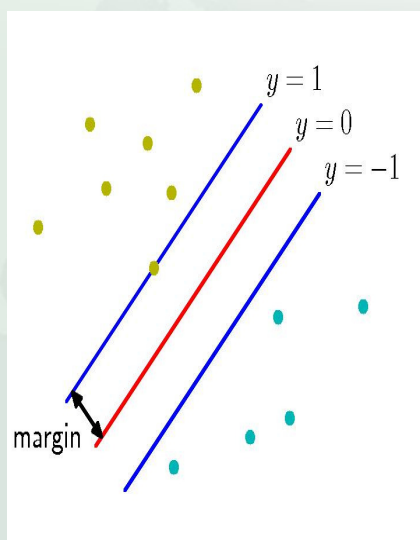


- Untuk menentukan *decision boundary* (DB), yaitu suatu model linear atau *hyperplane* $y(\mathbf{x})$ dengan parameter \mathbf{w} dan b , SVM menggunakan konsep *margin* yang didefinisikan sebagai jarak terdekat antara DB dengan sembarang data training
- Dengan memaksimalkan *margin*, maka akan didapat suatu DB tertentu

13

Support Vector Machine

Maximum Margin



- Kenapa maksimum ?
- Berdasarkan intuisi, margin maksimum adalah pilihan yang aman karena jika terjadi sedikit kesalahan pada data maka akan memberikan kemungkinan terkecil terjadi kesalahan klasifikasi
- Berdasarkan teori, yang merupakan basis dari metode SVM, maksimum margin akan memberikan kapabilitas generalisasi terbaik (VC theory, 1960-1990)

14

SVM untuk Regresi

Bentuk Umum

- Model linear yang akan digunakan sebagai fungsi regresi memiliki bentuk umum sbb:

$$y(\mathbf{x}) = \mathbf{w}^T \phi(\mathbf{x}) + b$$

dimana \mathbf{x} adalah vektor input, \mathbf{w} adalah parameter bobot, $\phi(\mathbf{x})$ adalah fungsi transformasi fitur, dan b adalah suatu bias

15

SVM untuk Regresi

Formulasi Masalah

- Diberikan data pembelajaran $\{\mathbf{x}_n, t_n\}$, $n = 1 \dots N$. Pada model regresi linear sebelumnya, untuk mendapatkan parameter bobot \mathbf{w} dan bias b , kita meminimumkan fungsi error yang diregularisasi berikut ini:

$$E(\mathbf{w}, b) = \frac{1}{2} \sum_{n=1}^N (y(x_n) - t_n)^2 + \frac{\lambda}{2} \|\mathbf{w}\|^2$$

- Pada model SVR, kita akan meminimumkan fungsi error yang diregularisasi berikut ini:

$$E(\mathbf{w}, b) = C \sum_{n=1}^N E_\varepsilon(y(x_n) - t_n) + \frac{1}{2} \|\mathbf{w}\|^2$$


dimana $E_\varepsilon(\cdot)$ adalah fungsi error ε -insensitive yang didefinisikan sbb:

$$E_\varepsilon(y(x_n) - t_n) = \begin{cases} 0, & \text{jika } |y(x_n) - t_n| < \varepsilon \\ |y(x_n) - t_n| - \varepsilon, & \text{jika lainnya} \end{cases}$$

16

SVM untuk Regresi

Formulasi Masalah




- Untuk data target t_n yang terletak pada ϵ -tube akan memenuhi kondisi:
 - $t_n \leq y(x_n) + \epsilon$
 - $t_n \geq y(x_n) - \epsilon$
- Untuk data target t_n yang terletak diluar ϵ -tube, maka seperti pendekatan *soft-margin*, kita membutuhkan variabel *slack* $\xi_n, \bar{\xi}_n$ dimana $\xi_n > 0$ untuk $t_n > y(x_n) + \epsilon$, dan $\bar{\xi}_n > 0$ untuk $t_n < y(x_n) - \epsilon$, sehingga:
 - $t_n \leq y(x_n) + \epsilon + \xi_n$
 - $t_n \geq y(x_n) - \epsilon - \bar{\xi}_n$

17

SVM untuk Regresi

Formulasi Masalah

- Selanjutnya, penentuan parameter model SVR dapat diformulasikan sebagai masalah optimasi sbb:



$$\arg \min_{w, b} C \sum_{n=1}^N (\xi_n + \bar{\xi}_n) + \frac{1}{2} \|w\|^2$$

$$s.t. \quad \xi_n \geq 0, \quad \bar{\xi}_n \geq 0$$

$$t_n \leq y(x_n) + \epsilon + \xi_n$$

$$t_n \geq y(x_n) - \epsilon - \bar{\xi}_n$$

- Dengan kata lain, penentuan nilai parameter w dan b menjadi masalah pemrograman kuadrat (*quadratic programming*), yaitu meminimumkan suatu fungsi kuadrat dengan syarat suatu pertidaksamaan linear

18

SVM untuk Regresi

Bentuk Dual: Lagrange Multipliers

- Untuk menyelesaikan pemrograman kuadrat tersebut, cara yang umum digunakan adalah mencari bentuk dual dengan menggunakan perkalian Lagrange (*Lagrange multipliers*) $a_n \geq 0, \bar{a}_n \geq 0, \mu_n \geq 0, \bar{\mu}_n \geq 0$ dengan satu pengali Lagrange untuk setiap kendala, untuk membentuk fungsi Lagrangian (*Lagrangian function*) sbb:

$$L(w, b, a, \bar{a}, \mu, \bar{\mu}) = C \sum_{n=1}^N (\xi_n + \bar{\xi}_n) + \frac{1}{2} \|w\|^2 - \sum_{n=1}^N (\mu_n \xi_n + \bar{\mu}_n \bar{\xi}_n) - \sum_{n=1}^N a_n (\varepsilon + \xi_n + y(x_n) - t_n) - \sum_{n=1}^N \bar{a}_n (\varepsilon + \bar{\xi}_n - y(x_n) + t_n)$$

19

SVM untuk Regresi

Bentuk Dual: Lagrange Multipliers

- Dengan menurunkan L terhadap w , b , ξ_n , dan $\bar{\xi}_n$ sama dengan nol, maka:

$$\frac{\partial L}{\partial w} = w - \sum_{n=1}^N (a_n - \bar{a}_n) \phi(x_n) = 0 \rightarrow w = \sum_{n=1}^N (a_n - \bar{a}_n) \phi(x_n)$$

$$\frac{\partial L}{\partial b} = \sum_{n=1}^N a_n - \sum_{n=1}^N \bar{a}_n = 0 \rightarrow \sum_{n=1}^N (a_n - \bar{a}_n) = 0$$

$$\frac{\partial L}{\partial \xi_n} = C - a_n - \mu_n = 0 \rightarrow a_n + \mu_n = C$$

$$\frac{\partial L}{\partial \bar{\xi}_n} = C - \bar{a}_n - \bar{\mu}_n = 0 \rightarrow \bar{a}_n + \bar{\mu}_n = C$$

20

SVM untuk Regresi

Bentuk Dual: Fungsi Kernel

- Substitusikan hasil turunan tsb ke persamaan Lagrangian, yaitu:

$$L = C \sum_{n=1}^N (\xi_n + \bar{\xi}_n) + \frac{1}{2} \|w\|^2 - \sum_{n=1}^N (\mu_n \xi_n + \bar{\mu}_n \bar{\xi}_n) - \sum_{n=1}^N a_n (\varepsilon + \xi_n + y(x_n) - t_n) - \sum_{n=1}^N \bar{a}_n (\varepsilon + \bar{\xi}_n - y(x_n) + t_n)$$

sehingga menjadi:

$$\tilde{L}(a, \bar{a}) = -\frac{1}{2} \sum_{n=1}^N \sum_{m=1}^N (a_n - \bar{a}_n)(a_m - \bar{a}_m) k(x_n, x_m) - \varepsilon \sum_{n=1}^N (a_n + \bar{a}_n) + \sum_{n=1}^N (a_n - \bar{a}_n) t_n$$

21

SVM untuk Regresi

Bentuk Dual

- Sehingga, bentuk *dual* dari masalah SVR adalah:

$$\arg \max_{a, \bar{a}} -\frac{1}{2} \sum_{n=1}^N \sum_{m=1}^N (a_n - \bar{a}_n)(a_m - \bar{a}_m) k(x_n, x_m) - \varepsilon \sum_{n=1}^N (a_n + \bar{a}_n) + \sum_{n=1}^N (a_n - \bar{a}_n) t_n$$

$$s.t. \quad 0 \leq a_n \leq C, \quad 0 \leq \bar{a}_n \leq C$$

$$\sum_{n=1}^N (a_n - \bar{a}_n) = 0$$

- Representasi dual yang dihasilkan adalah berupa pemrograman kuadrat juga, akan tetapi memiliki kendala yang lebih sederhana (*bound-constrained optimization*).

22

SVM untuk Regresi

Solusi Bentuk Dual: Algoritma

- Ada beberapa algoritma dan perangkat lunak yang telah dikembangkan untuk memecahkan masalah optimisasi dari SVM, antara lain:
 - SMO [2]
 - LibSVM [3] (<http://www.csie.ntu.edu.tw/~cjlin/libsvm>)
 - SVM^{Light} [4] (<http://svmlight.joachims.org>)

23

SVM untuk Regresi

Solusi Bentuk Dual: Nilai Bobot

- Misal, solusi dari pemrograman kuadrat bentuk dual tersebut adalah \mathbf{a}^* dan $\bar{\mathbf{a}}^*$, maka:

$$w = \sum_{n=1}^N (a_n^* - \bar{a}_n^*) \phi(x_n)$$

$$y(x) = w^T \phi(x) + b = \sum_{n=1}^N (a_n^* - \bar{a}_n^*) k(x, x_n) + b$$

- Hanya data dengan $a_n^* > 0$, $\bar{a}_n^* > 0$ (*support vectors*) yang berperan pada model SVR, sehingga dapat ditulis menjadi:

$$y(x) = \sum_{m \in S} (a_m^* - \bar{a}_m^*) k(x, x_m) + b$$

dimana S adalah himpunan indeks dari *support vectors*

24

SVM untuk Regresi

Solusi Bentuk Dual: Karush-Kuhn-Tucker

Karush-Kuhn-Tucker (KKT) conditions yang menyatakan bahwa solusi yang diperoleh adalah optimal, atau pada solusi tersebut variabel dan kendala dari bentuk dual bertemu, adalah sbb:

$$a_n(\epsilon + \xi_n + y_n - t_n) = 0 \quad [KKT-1]$$

$$\bar{a}_n(\epsilon + \bar{\xi}_n - y_n + t_n) = 0 \quad [KKT-2]$$


$$(C - a_n)\xi_n = 0 \quad [KKT-3]$$

$$(C - \bar{a}_n)\bar{\xi}_n = 0 \quad [KKT-4]$$

25

SVM untuk Regresi

Solusi Bentuk Dual: Support Vectors



- *Support vectors* adalah data training dengan nilai $a_n^* > 0, \bar{a}_n^* > 0$
- Berdasarkan [KKT-1] maka $\epsilon + \xi_n + y_n - t_n = 0$. Dengan kata lain, data training terletak pada *boundary* atas ($\xi_n = 0$) atau diatas *boundary* atas ($\xi_n > 0$)
- Berdasarkan [KKT-2] maka $\epsilon + \bar{\xi}_n - y_n + t_n = 0$. Dengan kata lain, data training terletak pada *boundary* bawah ($\bar{\xi}_n = 0$) atau dibawah *boundary* bawah ($\bar{\xi}_n > 0$)

26

SVM untuk Regresi

Solusi Bentuk Dual: Nilai Bias

- Selanjutnya, b dapat dicari dengan memperhatikan kondisi sebelumnya, sbb:

- (1) $0 < a_n < C$ (*kendala, slide 16*)
- (2) $(C - a_n)\xi_n = 0$ (*KKT-3, slide 18*)
- (3) $a_n(\varepsilon + \xi_n + y_n - t_n) = 0$ (*KKT-1, slide 18*)
- (4) $y(x) = w^T \phi(x) + b$

Dari (2) maka $\xi_n = 0$, dari (3) maka $\varepsilon + y_n - t_n = 0$, selanjutnya b dapat dicari dari (4) sbb:

$$\begin{aligned} b &= y(x_n) - w^T \phi(x_n) \\ &= t_n - \varepsilon - w^T \phi(x_n) \\ &= t_n - \varepsilon - \sum_{m \in S} (a_m^* - \bar{a}_m^*) k(x_n, x_m) \end{aligned}$$

27

SVM untuk Regresi

Prediksi Data Baru

- Misal diberikan data \mathbf{z} , maka prediksi dari data tersebut ditentukan berdasarkan fungsi regresi $y(\mathbf{x})$, yaitu: $y(\mathbf{z})$

28

SVM untuk Regresi

Black Box

- Pada pembahasan SVM pada presentasi ini, beberapa bagian masih bersifat *black box*, yaitu:
 - **VC Theory**, yaitu teori yang mendasari metode margin maksimum yang menunjukkan bahwa margin maksimum akan memberikan generalisasi error terkecil [1]
 - Algoritma penyelesaian masalah pemrograman kuadrat (bentuk dual dari *soft margin*), misal algoritma SMO [2], LibSVM [3], SVM^{Light} [4]

29

Referensi

- (1) C. H. Bishop. *Pattern Recognition and Machine Learning*, Springer, 2006 (Bab 7.1, Bab 7.1.1, Bab 7.1.3, Appendix E)
- (2) J. C. Platt. *Fast training of support vector machines using sequential minimal optimization*. In B. Schoelkopf, C. J. C. Burges, and A. J. Smola (Eds), *Advances in Kernel Methods – Support Vector Learning*, pp. 185-208, MIT Press, 1999
- (3) R. E. Fan, P. H. Chen, C. J. Lin. *Working set selection using second order information for training SVM*. *Journal of Machine Learning Research* 6, 1889-1918, 2005
- (4) T. Joachim. *Making Large-Scale SVM Learning Practical*. In B. Schoelkopf, C. J. C. Burges, and A. J. Smola (Eds), *Advances in Kernel Methods – Support Vector Learning*, pp. 169-184, MIT Press, 1999