

Support Vector Machine


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 $\mathbf{t}_i, i = 1 \text{ as } N$

- **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 pengklasifikasian (*classification*) dan regresi (*regression*)
- **Unsupervised Learning.** Data pelatihan tidak disertai target, yaitu $\mathbf{x}_i, i = 1 \text{ sd } N$. Tujuan pembelajaran adalah membangun model yang dapat menemukan variabel tersembunyi pada data pelatihan. Selanjutnya, variabel tersembunyi tersebut dapat digunakan untuk kebutuhan pemodelan (*latent variable models*)

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:

$$w * k(\mathbf{x}, 5) = 0.04 * \phi(\|\mathbf{x} - 5\|)$$


$$= 0.04 * \exp(-\|\mathbf{x} - 5\|^2 / 2s^2)$$



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

Two-Class Classification Problem



- Diberikan data pembelajaran $\{\mathbf{x}_n, t_n\}$, $n = 1$ sd N , yang diklasifikasikan dalam dua kelas, yaitu kelas R_1 ($t_n = +1$) dan kelas R_2 ($t_n = -1$)
- Permasalahan: bagaimana menentukan *decision boundary* yang dapat mengklasifikasikan data dengan benar

13

Support Vector Machine

Bentuk Umum

- *Support Vector Machine (SVM)* menggunakan model linear sebagai *decision boundary* dengan 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 basis, dan b adalah suatu bias

14

Support Vector Machine

Hyperplane



- Bentuk model linear yang paling sederhana untuk *decision boundary* adalah:

$$y(\mathbf{x}) = \mathbf{w}^T \mathbf{x} + w_0$$


Dimana \mathbf{x} adalah vektor input, \mathbf{w} adalah vektor bobot dan w_0 adalah bias.

- Sehingga, *decision boundary* adalah $y(\mathbf{x})=0$, yaitu suatu *hyperplane* berdimensi $(D-1)$
- Suatu vektor input \mathbf{x} akan diklasifikasikan ke kelas 1 (R_1) jika $y(\mathbf{x}) \geq 0$, dan kelas 2 (R_2) jika $y(\mathbf{x}) < 0$

15

Support Vector Machine

Sifat-Sifat Hyperplane




- Jika \mathbf{x}_A dan \mathbf{x}_B terletak pada *decision boundary* (DS), maka $y(\mathbf{x}_A) = y(\mathbf{x}_B) = 0$ atau $\mathbf{w}^T(\mathbf{x}_A - \mathbf{x}_B) = 0$, sehingga \mathbf{w} tegak lurus terhadap semua vektor di DS. Dengan kata lain \mathbf{w} menentukan orientasi dari DS
- Jarak titik awal ke DS adalah $-w_0 / \|\mathbf{w}\|$. Dengan kata lain w_0 menentukan lokasi DS.
- Jarak sembarang vektor \mathbf{x} ke DS dan searah \mathbf{w} adalah $y(\mathbf{x}) / \|\mathbf{w}\|$

16

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

17

Support Vector Machine

Maximum Margin

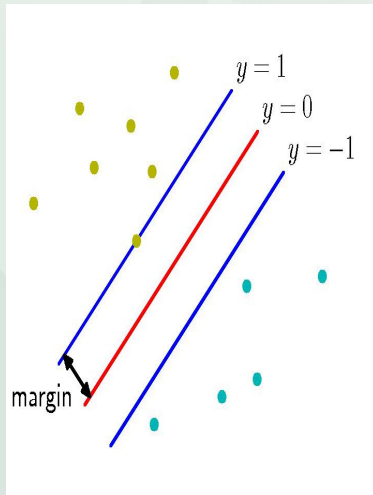


- Kenapa maksimum ?
- Berdasarkan intuisi, margin maksimum adalah pilihan yang aman karena jika terjadi sedikit kesalahan pada data maka akan memberikan kemungkinan terkecil terjadi kesalahan klasifikasi
- Berdasarkan teori, yang merupakan basis dari metode SVM, maksimum margin akan memberikan kapabilitas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

18

Support Vector Machine

Maximum Margin



- Asumsikan semua data terklasifikasi dengan benar (*linearly separable*), maka jarak antara sembarang data x_n ke *decision boundary* (DB) adalah:

$$\frac{t_n y(x_n)}{\|w\|} = \frac{t_n (w^T \phi(x_n) + b)}{\|w\|}$$

- Margin adalah jarak antara DB dan data terdekat, sehingga memaksimalkan margin dapat dideskripsikan sbb:


$$\arg \max_{w, b} \left\{ \frac{1}{\|w\|} \min_n [t_n (w^T \phi(x_n) + b)] \right\}$$

19

Support Vector Machine

Maximum Margin

- Solusi langsung dari masalah optimasi sebelumnya akan sangat kompleks, sehingga perlu dikonversi ke masalah yang ekuivalen yang lebih mudah diselesaikan



- Salah satu metode adalah menggunakan bentuk kanonik dari DB, yaitu:

$$t_n (w^T \phi(x_n) + b) = 1$$

untuk data yang terdekat ke DB. Selanjutnya, semua data pembelajaran akan memenuhi kondisi berikut ini:

$$t_n (w^T \phi(x_n) + b) \geq 1$$

20

Support Vector Machine

Quadratic Programming

- Selanjutnya, masalah optimasi sebelumnya dapat disederhanakan menjadi memaksimum $1/\|w\|$ yang ekuivalen dengan meminimumkan $\|w\|^2$
- Sehingga masalah optimasi-nya menjadi (bentuk *primal*):


$$\begin{aligned} \arg \min_{w, b} \quad & \frac{1}{2} \|w\|^2 \\ \text{s.t.} \quad & t_n (w^T \phi(x_n) + b) \geq 1, \quad n=1, \dots, N \end{aligned}$$

- 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

21

Support Vector Machine

Soft Margin: Landasan




- Diberikan data pembelajaran $\{x_n, t_n\}$, $n = 1$ sd N , $t_n \in \{-1, +1\}$.
- Pada formulasi masalah sebelumnya, semua data diasumsikan *linearly separable* pada ruang fitur $\phi(x)$.
- Dalam aplikasi praktis, kondisi tersebut sering tidak terpenuhi bahkan setelah data di transformasi ke ruang fitur $\phi(x)$.
- Masalah ini dipecahkan dengan memodifikasi formulasi masalah sebelumnya dengan cara membuat margin lunak (soft margin) yang memungkinkan beberapa data pada „posisi yang salah“

22

Support Vector Machine

Soft Margin: Formulasi Masalah



- Untuk merealisasikan *soft margin* ini, diperkenalkan variabel *slack*, $\xi_n \geq 0$, $n=1, \dots, N$, dengan satu variabel *slack* untuk masing-masing data pembelajaran
- Variabel *slack* tersebut bernilai $\xi_n = |t_n - y(x_n)|$
- Sehingga, $\xi_n = 0$ adalah data yang terletak pada *margin* dan sisi yang benar, $0 < \xi_n \leq 1$ adalah data yang terletak didalam *margin* pada sisi yang benar, dan $\xi_n > 1$ adalah data yang terletak pada sisi yang salah

23

Support Vector Machine

Soft Margin: Quadratic Programming

- Bentuk primal dari masalah optimasi sebelumnya (*hard margin*) adalah:

$$\arg \min_{w, b} \frac{1}{2} \|w\|^2$$

$$s.t. \quad t_n (w^T \phi(x_n) + b) \geq 1, \quad n=1, \dots, N$$

maka bentuk primal dari masalah optimasi untuk *soft margin* adalah:

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

$$s.t. \quad t_n (w^T \phi(x_n) + b) \geq 1 - \xi_n, \quad n=1, \dots, N$$

$$\xi_n \geq 0$$

dimana parameter $C > 0$ akan mengontrol *trade-off* antara pinalti variabel *slack* dan *margin*

24

Support Vector Machine

Bentuk Dual : Lagrange Multipliers

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

$$L(w, b, a) = \frac{1}{2} \|w\|^2 + C \sum_{n=1}^N \xi_n - \sum_{n=1}^N a_n \{t_n (w^T \phi(x_n) + b) - 1 + \xi_n\} - \sum_{n=1}^N \mu_n \xi_n$$

25

Support Vector Machine

Bentuk Dual : Lagrange Multipliers

$$L(w, b, a) = \frac{1}{2} \|w\|^2 + C \sum_{n=1}^N \xi_n - \sum_{n=1}^N a_n \{t_n (w^T \phi(x_n) + b) - 1 + \xi_n\} - \sum_{n=1}^N \mu_n \xi_n$$

- Dengan menurunkan $L(\mathbf{w}, b, \mathbf{a})$ terhadap \mathbf{w} dan b sama dengan nol, maka:

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

$$\frac{\partial L}{\partial b} = \sum_{n=1}^N a_n t_n = 0 \rightarrow 0 = \sum_{n=1}^N a_n t_n$$

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

26

Support Vector Machine

Bentuk Dual : Fungsi Kernel

- Substitusikan hasil turunan tsb ke persamaan Lagrangian, yaitu:

$$L(w, b, a) = \frac{1}{2} \|w\|^2 + C \sum_{n=1}^N \xi_n - \sum_{n=1}^N a_n \{t_n (w^T \phi(x_n) + b) - 1 + \xi_n\} - \sum_{n=1}^N \mu_n \xi_n$$

sehingga menjadi:

$$\begin{aligned} \tilde{L}(a) &= \frac{1}{2} \sum_{n=1}^N \sum_{m=1}^N a_n a_m t_n t_m \phi(x_n)^T \phi(x_m) - \sum_{n=1}^N \sum_{m=1}^N a_n a_m t_n t_m \phi(x_n)^T \phi(x_m) - b \sum_{n=1}^N \sum_{m=1}^N a_n t_m + \sum_{n=1}^N a_n \\ &= \sum_{n=1}^N a_n - \frac{1}{2} \sum_{n=1}^N \sum_{m=1}^N a_n a_m t_n t_m \phi(x_n)^T \phi(x_m) \\ &= \sum_{n=1}^N a_n - \frac{1}{2} \sum_{n=1}^N \sum_{m=1}^N a_n a_m t_n t_m k(x_n, x_m) \end{aligned}$$

27

Support Vector Machine

Bentuk Dual

- Sehingga, bentuk *dual* dari masalah *soft margin* maksimum adalah:

$$\arg \max_a \tilde{L}(a) = \sum_{n=1}^N a_n - \frac{1}{2} \sum_{n=1}^N \sum_{m=1}^N a_n a_m t_n t_m k(x_n, x_m)$$

$$s.t. \quad 0 \leq a_n \leq C, \quad n=1, \dots, N$$

$$\sum_{n=1}^N a_n t_n = 0$$

- Bentuk dual yang dihasilkan juga berupa pemrograman kuadrat dengan kendala yang lebih sederhana (*bound-constrained optimization*).
- Terlihat bahwa masalah pemrograman kuadrat dari *hard margin* dan *soft margin* adalah identik, kecuali bagian kendalanya yang sedikit berbeda

28

Support Vector Machine

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>)

29

Support Vector Machine

Solusi Bentuk Dual : Nilai Bobot

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

$$w = \sum_{n=1}^N a_n^* t_n \phi(x_n)$$

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

- Hanya data dengan $a_n^* > 0$ (*support vectors*) yang berperan pada model *decision boundary* diatas, sehingga dapat ditulis menjadi:

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

dimana S adalah himpunan indeks dari *support vectors*

30

Support Vector Machine

Solusi Bentuk Dual : Kondisi *Karush-Kuhn-Tucker*


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

$$\begin{aligned}
 a_n &\geq 0 && [KKT - S1] \\
 t_n y(x_n) - 1 + \xi_n &\geq 0 && [KKT - S2] \\
 a_n \{t_n y(x_n) - 1 + \xi_n\} &= 0 && [KKT - S3] \\
 \mu_n &\geq 0 && [KKT - S4] \\
 \xi_n &\geq 0 && [KKT - S5] \\
 \mu_n \xi_n &= 0 && [KKT - S6]
 \end{aligned}$$

31

Support Vector Machine

Solusi Bentuk Dual : *Support Vectors*



- *Support vectors* adalah data training dengan nilai $a_n^* > 0$, maka dari [KKT-S3]

$$t_n y(x_n) = 1 - \xi_n$$
- Jika $a_n^* < C$, maka berdasarkan hasil turunan bahwa $a_n = C - \mu_n$ maka $\mu_n > 0$. Selanjutnya, berdasarkan [KKT-S6] $\mu_n \xi_n = 0$ maka $\xi_n = 0$. Dengan kata lain adalah data training yang terletak pada hyperplane
- Jika $a_n^* = C$, maka $\mu_n = 0$. Dari [KKT-S6] maka $\xi_n \neq 0$. Dengan kata lain adalah data training yang terletak didalam margin, baik yang terklasifikasi dengan benar ($\xi_n \leq 1$) atau salah ($\xi_n > 1$)

32

Support Vector Machine

Solusi Bentuk Dual : Nilai Bias

- Selanjutnya, b dapat dicari dengan cara sbb:

$$t_n y(x_n) = 1$$

$$t_n \left(\sum_{m \in S} a_m^* t_m k(x_n, x_m) + b \right) = 1 \rightarrow b = \frac{1}{N_S} \sum_{n \in S} (t_n - \sum_{m \in S} a_m^* t_m k(x_n, x_m))$$

dimana S adalah himpunan indeks dari *support vectors*, dan N_S adalah jumlah semua *support vectors*

33

Support Vector Machine

Prediksi Data Baru

- Misal diberikan data \mathbf{z} , maka prediksi dari data tersebut ditentukan berdasarkan fungsi $y(\mathbf{x})$, yaitu:
 - Jika $y(\mathbf{z}) \geq 0$ maka \mathbf{z} adalah kelas C_1 ($t = +1$)
 - Jika $y(\mathbf{z}) < 0$ maka \mathbf{z} adalah kelas C_2 ($t = -1$)

34

Support Vector Machine

Multi-Class Classification

- Multi-class classification adalah masalah klasifikasi yang memiliki jumlah kelas lebih dari 2. Sementara SVM standar didesain untuk masalah two-class classification. Ada beberapa teknik yang memungkinkan penggunaan SVM standar two-class untuk masalah multi-class, misal K kelas, yaitu:
 - *One-vs-The Rest*, yaitu membangun K buah SVM, dimana model ke- k , yaitu $y_k(\mathbf{x})$, dilatih dengan menggunakan data dari kelas C_k sebagai sampel positif (+1) dan data dari kelas yang lain sebagai sampel negatif (-1). Contoh: $y_1(\mathbf{x})$ akan memisahkan antara kelas 0 dan kelas-kelas lainnya (1,2,3,4)
 - *One-vs-One*, yaitu membangun $K(K-1)/2$ buah SVM yang merupakan semua kemungkinan pasangan kelas, selanjutnya suatu data pengujian akan diklasifikasikan ke kelas yang menang paling banyak. Contoh: $y_1(\mathbf{x})$ akan memisahkan kelas 0 dan kelas 1, $y_2(\mathbf{x})$ akan memisahkan kelas 1 dan kelas 2, dst

35

Support Vector Machine

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 SVM^{Light} [2], SMO [3], LibSVM [4]

36



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