

Model Linear untuk Klasifikasi


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



Diberikan data pelatihan (*training data*), yaitu x_i dan/atau t_i , $i = 1$ sd N

- *Preprocessing*: pemilihan/ekstraksi fitur dari data, misal $x_i = (x_1, x_2, \dots, x_D)^T$
- *Learning*: penentuan parameter metode, misal w , berdasarkan data pelatihan
- *Testing*: pengujian metode dengan data baru. Data penguji (*testing data*) tersebut harus dilakukan *preprocessing* yang sama dengan data pembelajaran sebelum dieksekusi oleh metode

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 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

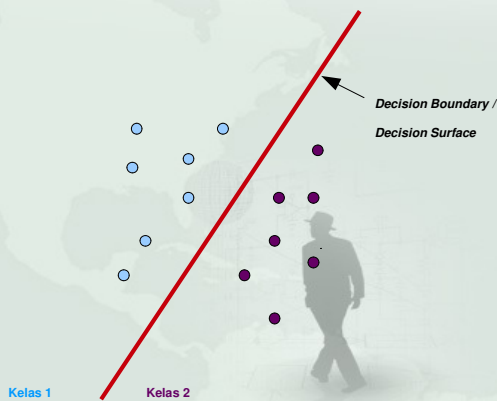
- **Regresi**
 - Nilai output \mathbf{t}_i bernilai kontinu (riil)
 - Bertujuan memprediksi output dari data baru dengan akurat
- **Klasifikasi**
 - Nilai output \mathbf{t}_i bernilai diskrit (kelas)
 - Bertujuan mengklasifikasi data baru dengan akurat



4

Klasifikasi

Masalah Dua Kelas



- Diberikan vektor input \mathbf{x} berdimensi D , bagaimana mengklasifikasikannya pada salah satu kelas
- Salah satu cara adalah mencari batas (*decision boundary/decision surface*) antara area kelas (*decision region*) berdasarkan data pembelajaran
- Misal dengan menggunakan fungsi linear (model linear) yang dikenal juga dengan istilah fungsi diskriminan (*discriminant function*)

5

Klasifikasi

Model Linear

- Model linear adalah kombinasi linear dari fungsi nonlinear dari variabel input:

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


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

6

Klasifikasi

Hyperplane



- Bentuk model linear yang paling sederhana untuk fungsi diskriminan linear:

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


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 $y(\mathbf{x}) < 0$

7

Klasifikasi

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 $y(\mathbf{x}) / \|\mathbf{w}\|$

8

Perceptron

Bentuk Umum

- Asumsikan kita memiliki data pembelajaran $\{\mathbf{x}_n, t_n\}$, $n = 1$ sd N . Suatu vektor input \mathbf{x} pertama-tama ditransformasi menggunakan suatu transformasi nonlinear $\phi(\cdot)$ untuk membentuk vektor fitur $\phi(\mathbf{x})$ yang digunakan untuk membentuk model linear dengan bentuk:

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

dimana fungsi aktivasi nonlinear $f(\cdot)$ diberikan oleh fungsi tangga dengan bentuk:

$$f(a) = +1 \text{ jika } a \geq 0$$

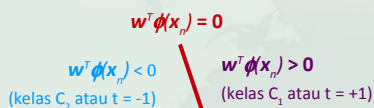
$$f(a) = -1 \text{ jika } a < 0.$$

- Vektor $\phi(\mathbf{x})$ biasanya mengandung komponen bias $\phi_0(\mathbf{x}) = 1$

9

Perceptron

Kriteria Perceptron



$w^T \phi(\mathbf{x}_n) = 0$

$w^T \phi(\mathbf{x}_n) < 0$
(kelas C_2 atau $t = -1$)

$w^T \phi(\mathbf{x}_n) > 0$
(kelas C_1 atau $t = +1$)

- Diberikan data pembelajaran \mathbf{x}_n dan t_n , dimana $t_n = +1$ untuk kelas C_1 dan $t_n = -1$ untuk kelas C_2
- Untuk setiap vektor \mathbf{x}_n di kelas C_1 akan membuat $w^T \phi(\mathbf{x}_n) > 0$, dan untuk setiap vektor \mathbf{x}_n di kelas C_2 akan membuat $w^T \phi(\mathbf{x}_n) < 0$
- Sehingga, semua vektor \mathbf{x}_n akan diklasifikasi dengan benar jika $w^T \phi(\mathbf{x}_n) t_n > 0$

10

Perceptron

Fungsi Error

- Untuk setiap vektor \mathbf{x} yang tidak diklasifikasikan dengan benar, maka metode perceptron akan meminimumkan fungsi error, disebut juga kriteria perceptron (*perceptron criterion*), sbb:

$$E_p(\mathbf{w}) = - \sum_{n \in M} \mathbf{w}^T \phi(\mathbf{x}_n) t_n$$

Dimana M adalah himpunan indeks vektor \mathbf{x} yang tidak diklasifikasikan dengan benar

- Sehingga, bobot diperbarui secara berulang sbb:

$$\mathbf{w}^{(\tau+1)} = \mathbf{w}^{(\tau)} - \eta \nabla E_p(\mathbf{w}) = \mathbf{w}^{(\tau)} + \eta \phi(\mathbf{x}_n) t_n$$

dimana η adalah parameter *learning rate*, dan τ ada langkah dari iterasi algoritma

11

Perceptron

Algoritma

- 1) $\{(\mathbf{x}_1, t_1), \dots, (\mathbf{x}_N, t_N)\}$ adalah data pembelajaran
- 2) Inisialisasi $\mathbf{w}^{(0)}$ dengan bilangan random
- 3) Untuk setiap data pembelajaran (\mathbf{x}_n, t_n) , Jika data diklasifikasikan dengan benar maka tidak ada perubahan terhadap \mathbf{w}
- 4) Untuk setiap data pembelajaran (\mathbf{x}_n, t_n) , Jika data pembelajaran tidak diklasifikasikan dengan benar maka \mathbf{w} diperbarui sbb:

$$\mathbf{w}^{(\tau+1)} = \mathbf{w}^{(\tau)} - \eta \nabla E_p(\mathbf{w}) = \mathbf{w}^{(\tau)} + \eta \phi(\mathbf{x}_n) t_n$$


12

Perceptron

Contoh

Diberikan data sebagai berikut

No	x_1	x_2	Kelas (t)
1	1	1	+1
2	1	-1	-1
3	-1	1	-1
4	-1	-1	-1



Tentukan *hyperplane* yang menjadi batas (*decision boundary*) dari ke dua kelas dari data tersebut dengan menggunakan metode perceptron!

13

Perceptron


Contoh

Misal $\eta = 1$, $\phi(\mathbf{x}) = \mathbf{x}$, $\phi_0(\mathbf{x}) = 1$, $\mathbf{w}^{(0)} = (0, 0, 0)$

1) Ambil $\mathbf{x}_1 = (1, 1)^T$ dan $t_1 = +1$ sebagai data pembelajaran:

$$\begin{aligned}\mathbf{w}^{(1)} &= \mathbf{w}^{(0)} + \eta \phi(\mathbf{x}_1) t_1 \\ &= \mathbf{w}^{(0)} + \eta (1, x_1, x_2)^T t_1 \\ &= (0, 0, 0)^T + 1 \cdot (1, 1, 1)^T \cdot 1 \\ &= (1, 1, 1)^T\end{aligned}$$

sehingga *decision boundary* adalah $1 + x_1 + x_2 = 0$



14


Perceptron

Contoh

- 2) Ambil $\mathbf{x}_2 = (1, -1)^T$ dan $t_2 = -1$ sebagai data pembelajaran:

$$\begin{aligned}\mathbf{w}^{(2)} &= \mathbf{w}^{(1)} + \eta \phi(\mathbf{x}_2) t_2 \\ &= \mathbf{w}^{(1)} + \eta (1, x_1, x_2) t_2 \\ &= (1, 1, 1)^T + 1 \cdot (1, 1, -1)^T \cdot -1 \\ &= (0, 0, 2)^T\end{aligned}$$

sehingga *decision boundary* adalah $2x_2 = 0$



15


Perceptron

Contoh

- 3) Ambil $\mathbf{x}_3 = (-1, 1)^T$ dan $t_3 = -1$ sebagai data pembelajaran:

$$\begin{aligned}\mathbf{w}^{(3)} &= \mathbf{w}^{(2)} + \eta \phi(\mathbf{x}_3) t_3 \\ &= \mathbf{w}^{(2)} + \eta (1, x_1, x_2) t_3 \\ &= (0, 0, 2)^T + 1 \cdot (1, -1, 1)^T \cdot -1 \\ &= (-1, 1, 1)^T\end{aligned}$$

sehingga *decision boundary* adalah $-1 + x_1 + x_2 = 0$



16

Perceptron

Beberapa Catatan

- Pada tahun 1962, Novikoff telah membuktikan teorema pertama tentang perceptron. Teorema ini memulai teori tentang pembelajaran (*learning*) yang menyatakan bahwa jika
 - Norm dari vektor input \mathbf{x} dibatasi oleh konstanta R ($|\mathbf{x}| \leq R$)
 - Data pembelajaran dapat dipisahkan dengan margin ρ :Maka setelah paling banyak $K \leq \lceil R^2/\rho^2 \rceil$ koreksi, *hyperplane* yang memisahkan data pembelajaran akan dibentuk
- Perceptron telah menunjukkan kapabilitas generalisasi pada contoh kasus sederhana

17

Referensi

- Bishop, C. H., *Pattern Recognition and Machine Learning*, Springer, 2006 (Bab 4.1.1, Bab 4.1.7)