

Subject:

Year. Month. Date. (Z)

سناساپي آھاري الكو:

rahmati@aut.ac.ir

* منتخب استاد
دكتور رحمتي
آدرس بيت البريدي
ارتباط با استاد

to: rahmati@aut.ac.ir

subject: SPR member

content:

Name: _____

S.N: _____

Email: _____

* منابع

1. Introduction To Statistical Pattern Recognition
K. Fukunaga
Academic Press, 1990
2. Pattern Recognition
S. Theodoridis & K. Koutroumbass
Academic Press, 2003
3. Pattern Classification

* کتابشناسي
دورس ششم

نمبرال اول كتابي ۸۸-۸۷
"۳۳"
۰۹۱۲-۲۱۲۹۶۰۴

Subject: _____

Year: _____ Month: _____ Date: _____

* از زبان

- رطوبت (20%) ← پرده های کامپوزیتی + حمل میل
- آرزوی (60-65%) ← میان برآ + پایان برآ
- پرده پایانی (16-20%) ← برآیش + آینه + کجین دریا پیاده سازی

* مباحث

- مفهومات
- آمار و احتمالات
- جبر خطی
- تشخیص اناری اند
- کاهش ابعاد
- PCA -
- خودرشد بندی

* کاربرد؟

• بنیادی و شین

- خط تولید : صحت قطعات ، تشخیص قطعات
- تشخیص هدف خودکار : نظامی ، پزشکی
- تقادیر برای : ماهواره ای

• شناسایی حروف

- تشخیص مقدار نامه های پست
- خواندن متن اسکن شده

• پزشکی

- کنترل EEG ، ECG

- تقادیر پزشکی
- کمک به پزشک
- گفتار

(Human - Comp. Interface) HCI -

(Brain - Comp. Interface) BCI -

Action Recognition

سیستم های نظارتی

Video Sequencing -

* اجزای سیستم

• دنیای واقعی

- اخذ داده (سنسور) ← DB ، دوربین ، ECG
- پیش پردازش ← حذف نویز ، نرطال سازی ، استخراج ویژگی
- کلاسشن عدد ← حذف ویژگیها ، ادغام آنها
- پیش بینی ← اطلس بندی ، خوانند بندی
- انتخاب مدل

- * انداز پیش بینی
- کلاس بندی
- طبقه بندی
- Regression
- Description

Feature

- معرف ویژگی های ا ب شی
- ا ب شی را با برداری از ویژگی های نشان می دهند.
- انتخاب ویژگی ها در کلاس بندی موثر بسیار است
- ویژگی های دارای مقادیر جدا هستند.
- برای کلاس های مختلف باید دارای مقادیر مجزا باشد.

الگو

- * ترسیمی از ویژگی ها
- الگو = مجموعه ای از ویژگی ها + معانی آنها

طبقه بندی

- * فضای ویژگی ها را به نواحی مختلف افراز می کنند.
- مرز بین نواحی را decision boundary می گویند.
- تابع مدل این مرز بین نواحی کلاس بندی است.

روش های آماری

- آماری ← مقیاس های فضایی
- شبده سطحی ← شبده ای از سطوحی پردازنده
- ساختاری ← زیر ساختار و نظرس (تسایط)
- درخت تصمیم ← ؟

Subject:

Year. Month. Date. (3)

* هر ویژگی، یک متغیر تصادفی است

• برداری هر مقدار آن، یک برداری موجود است.

• مقادیر مختلفی برای پذیرد.

• چند ویژگی را به صورت بردار نشان می دهند (بردار ستونی)

$$\underset{\substack{\text{بردار} \\ n \times 1}}{X} = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix} = [x_1 \quad \dots \quad x_n]^T$$

• دارای یک تابع چگالی احتمال نشان داده می شود.

$P(x)$: probability density function

• دارای یک تابع توزیع تجمعی است

$P(x)$: probability distribution function = Prob { $X \leq x$ }

نماد:

X : Random Var.

$[\Sigma]$: Covariance Matrix of X

\underline{X} : Random vector

N : # of samples

α : Deterministic Var.

C, M : # of classes

d, n : Dimension

w_i : label of class. $i = 1, \dots, M$

T : Transpose

رابطه:

$$* P(\underline{x}) \equiv P(x_1, \dots, x_n) = \text{Prob} \{ X_1 \leq x_1, \dots, X_n \leq x_n \} = \text{Prob} \{ \underline{X} \leq \underline{x} \}$$

Joint Distribution

$$* \frac{\partial P_x(\underline{x})}{\partial \underline{x}} = p_x(\underline{x}) = P(\underline{x}) = \frac{\partial^n P(\underline{x})}{\partial x_1 \partial x_2 \dots \partial x_n}$$

$$* P(\underline{x}) = \int_{-\infty}^{+\infty} p(\underline{x}) d\underline{x} = \int_{-\infty}^{+\infty} \dots \int_{-\infty}^{+\infty} p(x_1, \dots, x_n) dx_1 \dots dx_n$$

$\underbrace{\hspace{10em}}_{\text{دیی}}$

Subject: _____

Year: _____ Month: _____ Date: _____

$$* \omega_i \quad i = 1, \dots, M$$

$\underline{x} \in \omega_i \rightarrow \underline{x}$ belongs to i^{th} class

$$p(\underline{x} | \omega_i) \equiv P_i(\underline{x})$$

conditional density function of class i

$$* P_{\underline{X}}(\underline{x}) \equiv P(\underline{x}) = \sum_{i=1}^M P_i \cdot P_i(\underline{x})$$

mixture (total) density function of \underline{X}

$$P_i = \text{Prob} \{ \omega_i \}$$

a priori probability of ω_i (احتمال اولیه)

$$* P(\omega_i | \underline{x}) \equiv q_i(\underline{x})$$

posterior probability of ω_i (احتمال ثانویه)

$$* P(\omega_i | \underline{x}) = P_i \cdot p_i(\underline{x}) = P(\omega_i | \underline{x}) \cdot p(\underline{x})$$

$$q_i(\underline{x}) = P(\omega_i | \underline{x}) = \frac{P_i \cdot P_i(\underline{x})}{P(\underline{x})} \quad \rightarrow \text{نرمالیزه کردن}$$

$$* i = 1, 2$$

$$q_1(\underline{x}) \quad \begin{array}{c} \omega_1 \\ \omega_2 \end{array} \quad q_{1X}(\underline{x})$$

$$P_1 \cdot P_1(\underline{x}) \quad \begin{array}{c} \omega_1 \\ \omega_2 \end{array} \quad P_2 \cdot P_2(\underline{x})$$

$$L(\underline{x}) \equiv \text{likelihood} = \frac{P_1(\underline{x})}{P_2(\underline{x})}$$

$$* m = E \{ X \}$$

$$\sigma_X^2 = E \{ (X - m)^2 \}$$

Subject:

Year: Month: Date: 14

معنی پارامتری توزیع

$$p_i(x) \quad i = 1, \dots, M$$

میانگین

$$\mu = m = E\{X\} = \int_{-\infty}^{+\infty} x \cdot p(x) dx$$

میانگین جدیدی

$$\underline{\mu} = \underline{m} = E\{X | \omega_i\} = \int_{-\infty}^{+\infty} x \cdot p(x) \cdot d\underline{x}$$

i^{th} element of X

$$m^i = i^{\text{th}} \text{ element of } E\{X\} = \int_{-\infty}^{+\infty} x_i \cdot p(x_i) = \int_{-\infty}^{+\infty} x_i \cdot p(x) \cdot d\underline{x}$$

marginal density

i^{th}

$$p(x_i) = \int_{-\infty}^{+\infty} \int_{-\infty}^{+\infty} p(x) dx_1 \dots dx_{i-1} dx_{i+1} \dots dx_n$$

i^{th}


ماتریس کوواریانس

$$[C] = [\Sigma]_X = E\{(X - \underline{m})(X - \underline{m})^T\}$$

$$= \begin{bmatrix} E\{(X_1 - m_1)^2\} = \sigma_1^2 & & \\ E\{(X_2 - m_2)(X_1 - m_1)\} & \sigma_2^2 & \\ & & \sigma_n^2 \end{bmatrix}$$

$$C_{i,j} = E\{(X_i - m_i)(X_j - m_j)\}$$

$i, j = 1, \dots, n$



Subject: _____

Year: _____

Month: _____

Date: _____

$$C_{ii} = \sigma_i^2$$

$$C_{ij} = \rho_{ij} \cdot \sigma_i \cdot \sigma_j$$

ρ_{ij} \equiv correlation coefficient of X_i & X_j

σ_i \equiv Standard Deviation of X_i

$$[C] = [\Sigma]_x = E \{ (\underline{X} - \underline{m})(\underline{X} - \underline{m})^T \}$$

$$= E \{ \underline{X}\underline{X}^T - \underline{X}\underline{m}^T - \underline{m}\underline{X}^T + \underline{m}\underline{m}^T \}$$

$$= E \{ \underline{X}\underline{X}^T \} + \underline{m}\underline{m}^T$$

$[R] = [E] \equiv$ Covariance Matrix of \underline{X}

$\underline{m}_{n \times 1} \equiv$ mean vector = $E \{ \underline{X} \}$

$$[\Sigma]_{n \times n} \equiv E \{ (\underline{X} - \underline{m})(\underline{X} - \underline{m})^T \} = \{ c_{ij} \mid c_{ij} = \rho_{ij} \cdot \sigma_i \cdot \sigma_j \}$$

$$[\Sigma] = [T][R][T]$$

$$[T] = \begin{bmatrix} \sigma_1 & & & \\ & \sigma_2 & & \\ & & \sigma_n & \\ & & & \sigma_n \end{bmatrix} \quad [R] = \begin{bmatrix} 1 & \rho_{12} & \rho_{13} & \dots & \rho_{1n} \\ & 1 & & & \\ & & 1 & & \\ & & & \ddots & \\ & & & & 1 \end{bmatrix}$$

ρ_{ij} \equiv correlation coeff. of X_i and X_j

Subject:

Year: Month: Date: 5)

(Gaussian Dist.) Normal Distribution *

$$P(\underline{x}) = N(\underline{m}, [\Sigma])$$

$$= \frac{1}{(2\pi)^{n/2} \cdot |[\Sigma]|^{1/2}} \exp\{-\frac{1}{2} d(\underline{x})\}$$

$d(\underline{x}) \equiv$ distance function \equiv Mahanobis dist $= (\underline{x} - \underline{m})^T [\Sigma]^{-1} (\underline{x} - \underline{m})$

$| \cdot | \equiv$ determinant of $[\Sigma]$

فیزیکی توجیه

Physical Justification -

تجزیاتی

$\underline{m}, [\Sigma]$ -

independent \leftarrow

uncorrelated -

uncorrelated $\iff C_{ij} = 0, i \neq j$

$$|\Sigma| = \begin{bmatrix} \sigma^2 & & & \\ & \ddots & & \\ & & \ddots & \\ & & & \sigma^2 \end{bmatrix}$$

uncorrelated $\iff [\Sigma] = [\Sigma]^{-1} \rightsquigarrow d(\underline{x})$ میں تغیر

$$P(\underline{x}) = P(x_1, x_2, \dots, x_n) = P(x_1) \cdot P(x_2) \cdot \dots \cdot P(x_n) \Rightarrow \text{independent}$$

Normal Marginal Distribution -

Normal Conditional Distribution -

Linear Transformation -

$$\underline{y} = [a]^T \underline{x}$$

Subject: _____

Year: _____

Month: _____

Date: _____

$$\underline{X} = \begin{bmatrix} X_1 \\ X_2 \end{bmatrix}_{2 \times 1}$$

$$\underline{Y} = [Y_1]_{1 \times 1}$$



$$P_{XY}(x_1, x_2, y_1) = \begin{cases} (x_1 + 3x_2) y_1 & , 0 \leq x_1, x_2, x_3 \leq 1 \\ 0 & , \text{ otherwise} \end{cases}$$

• event $\underline{Y} \leq \frac{1}{2}$

$$\text{Prob.} \{ \underline{Y} \leq \frac{1}{2} \} = \int_0^1 \int_{-\infty}^{1/2} (x_1 + 3x_2) y_1 \cdot dx_1 dy_1 = 1/4$$

• marginal dist \underline{X}

$$P_{\underline{X}}(x) = \int_{-\infty}^{+\infty} P_{XY}(x, y) \cdot dy = \int_0^1 (x_1 + 3x_2) \cdot y_1 \cdot dy_1$$

$$= \begin{cases} 0 & , \text{ otherwise} \\ \frac{1}{2} (x_1 + 3x_2) & , 0 \leq x_1, x_2 \leq 1 \end{cases}$$

• \underline{X} & \underline{Y} independent ?

$$P_{XY}(x, y) \stackrel{?}{=} P_{\underline{X}}(x) \cdot P_{\underline{Y}}(y)$$

* خاص $[\Sigma]$

مساكن

• Symmetric

• Positive Definite

مثبت قطري

$$\underline{a}^T [\Sigma] \underline{a} > 0$$

n x 1

$$• |\Sigma| > 0$$

$$• [\Sigma]^{-1} \text{ exist.}$$

• eigenvalues of $[\Sigma] > 0$ شماره ها مساكنات

Subject:

Year: _____ Month: _____ Date: _____ (6)

$$[\Sigma]_{n \times n} \underline{x} = \underline{\lambda} \underline{x}_{n \times 1}$$

$$\underline{\lambda} = \text{cte} \xrightarrow{[\Sigma] > 0} \lambda_1, \lambda_2, \dots, \lambda_n > 0$$

positive semi-definite

$$\underline{a}^T [\Sigma] \underline{a} \geq 0$$

$$[A] = \begin{bmatrix} 1 & -1 \\ -1 & 2 \end{bmatrix}$$

مثبت قطعی ✓

* تخمین زدن پارامتری m
1.0

$$X : x_i \quad i = 1, \dots, N$$

$$E\{X\} = m$$

$$\hat{m}_1 = \frac{1}{N} \sum_{i=1}^N x_i$$

نمونه N ①

$$\hat{m}_2$$

نمونه N ②

⋮

\hat{m} is Random Variable

$$E\{\hat{m}\} = \frac{1}{N} E\left\{\sum_{i=1}^N x_i\right\} = \frac{1}{N} \sum_{i=1}^N E\{x_i\} = \frac{1}{N} \cdot N \cdot m = m$$

Unbiased Estimation : اگر کسی مابطری باشد که رابطه کی با m برود m برود

Subject: _____

Year: _____ Month: _____ Date: _____

$$\begin{aligned}\hat{\sigma}_m^2 = \text{Var} \{ \hat{M} \} &= E \{ (\hat{M} - m)^2 \} \\ &= E \left\{ \left(\frac{1}{N} \sum_{i=1}^N X_i - m \right)^2 \right\} \\ &= E \left\{ \left(\frac{1}{N} \sum_{i=1}^N (X_i - m) \right) \left(\frac{1}{N} \sum_{j=1}^N (X_j - m) \right) \right\} \\ \text{با فرض استقلال آردی} &= E \{ (X_i - m) (X_j - m) \} \\ &= E \{ (X_i - m) \} \cdot E \{ (X_j - m) \} \\ &= \frac{1}{N^2} - N \cdot \sigma^2 = \frac{1}{N} \sigma^2\end{aligned}$$

$$N \rightarrow \infty : \hat{\sigma}_m^2 = 0$$

Consistent Estimation : بالا بودن تعداد نمونه = داراییس بطرف صفر میل کند

n-D •

$$\bar{m} = E \{ X \} = \frac{1}{N} \sum_{i=1}^N X_i$$

* تخمین زدن پارامتر [Σ]

1-D •

X

$$m = E \{ X \} \rightarrow \text{تخمین زدن میانه}$$

$$\sigma^2 = E \{ (X - m)^2 \}$$

$$\hat{\sigma}^2 = \frac{1}{N-1} \sum_{i=1}^N (X_i - \bar{X})^2$$

$$E \{ \hat{\sigma}^2 \} = \frac{1}{N-1} \sum_{i=1}^N E \{ X_i - \bar{X} \}^2 \quad \pm m$$

$$= \frac{1}{N-1} \sum_{i=1}^N \left(\sigma^2 + \frac{1}{N} \sigma^2 - 2 E \{ (X_i - m) (\bar{X} - m) \} \right)$$

Subject:

Year. Month. Date. (7)

n-D .

$$\underline{X}$$
$$\text{cov} \{ \underline{X} \} = [\hat{\Sigma}] = \frac{1}{N-1} \sum_{i=1}^N ((\underline{x}_i - \underline{m})(\underline{x}_i - \underline{m})^T)$$

راه آسانست .

$$[\Sigma] = [S] - \underline{m}\underline{m}^T$$

↳ autocorrelation matrix

$$[\hat{S}] = \frac{1}{N} \sum_{i=1}^N \underline{x}_i \cdot \underline{x}_i^T$$

Online learning

Iterative learning

Recursive learning

Incremental learning

دستی (4) N نمونه در دسترس نباشد به نتیجه یادگیری نرسد

$\underline{m}_N \equiv$ mean of \underline{X} based on first N samples

$$\begin{aligned} \underline{m}_N &= \frac{1}{N} \sum_{i=1}^N \underline{x}_i \\ &= \frac{1}{N} \left[\sum_{i=1}^{N-1} \underline{x}_i + \underline{x}_N \right] \\ &= \frac{1}{N} \left(\frac{N-1}{N-1} \sum_{i=1}^{N-1} \underline{x}_i + \underline{x}_N \right) \end{aligned}$$

$$\begin{aligned} &= \frac{N-1}{N} \cdot \frac{1}{N-1} \sum_{i=1}^{N-1} \underline{x}_i + \frac{1}{N} \underline{x}_N \\ &= \frac{N-1}{N} \underline{m}_{N-1} + \frac{1}{N} \underline{x}_N \\ &= \underline{m}_{N-1} - \frac{1}{N} \underline{m}_{N-1} + \frac{1}{N} \underline{x}_N \end{aligned}$$

$$\underline{m}_N = \underline{m}_{N-1} + \frac{1}{N} (\underline{x}_N - \underline{m}_{N-1})$$

تأثیر نمونه های آخر ضعیف تری شود

Subject: _____

Year: _____ Month: _____ Date: _____

$$\underline{m}_N = \underline{m}_{N-1} + \alpha \left(\underline{x}_N - \underline{m}_{N-1} \right)$$

بجای می شود.

Stationary α ضریب $\frac{1}{2}$ α

$$\underline{m}_N = (1-\alpha) \underline{m}_{N-1} + \alpha \underline{x}_N$$

$$[S] = \frac{1}{2} \sum_{i=1}^N \underline{x}_i \cdot \underline{x}_i^T$$

$$[S]_N = (1-\alpha) [S]_{N-1} + \alpha \underline{x}_N \cdot \underline{x}_N^T$$

$$[\Sigma] = [S] - \underline{m} \underline{m}^T$$

$$[\Sigma]_N = \left[(1-\alpha) [S]_{N-1} + \alpha \underline{x}_N \underline{x}_N^T \right] - \left[\underline{m} \right] \left[\underline{m} \right]^T$$

$$[\Sigma]_N = (1-\alpha) [\Sigma]_{N-1} + \alpha \left(\underline{x}_N - \underline{m}_{N-1} \right) \left(\underline{x}_N - \underline{m}_{N-1} \right)^T$$

OK

A = nxn C = mxm B, D = nxm

$$[A + BCD^T]^{-1} = A^{-1} - A^{-1} B [C^{-1} + D^T A^{-1} B]^{-1} D^T A^{-1}$$

$$[S]_N = \underbrace{(1-\alpha)}_A [S]_{N-1} + \alpha \underbrace{\underline{x}_N}_C \underbrace{\underline{x}_N^T}_D$$

$$[S]_N^{-1} = \frac{1}{1-\alpha} \left([S]_{N-1}^{-1} - \alpha \cdot \frac{[S]_{N-1}^{-1} \underline{x}_N \cdot \underline{x}_N^T \cdot [S]_{N-1}^{-1}}{1 + \alpha (\underline{x}_N^T \cdot [S]_{N-1}^{-1} \cdot \underline{x}_N - 1)} \right)$$

I. $[S]_0^{-1} \equiv$ initial inverse matrix $[S]^{-1}$

II. $\underline{w} = [S]_0^{-1} \cdot \underline{x}_1$

III. Update Equation

$$[S]_k^{-1} = \frac{1}{1-\alpha} \left([S]_{k-1}^{-1} - \alpha \frac{\underline{w} \underline{w}^T}{1 + \alpha (\underline{w}^T \underline{x}_k - 1)} \right)$$

• استناد داریم \hat{M}

$$[\hat{\Sigma}] = \frac{1}{N} \sum_{i=1}^N (\underline{x}_i - \hat{M})(\underline{x}_i - \hat{M})^T$$

آزمون unbiased بودن

$$[\hat{\Sigma}] = \frac{1}{N} \sum_{i=1}^N \{(\underline{x}_i - \underline{m}) - (\hat{M} - \underline{m})\} \{(\underline{x}_i - \underline{m}) - (\hat{M} - \underline{m})\}^T$$

$$= \frac{1}{N} \sum_{i=1}^N (\underline{x}_i - \underline{m})(\underline{x}_i - \underline{m})^T - (\hat{M} - \underline{m})(\hat{M} - \underline{m})^T$$

با فرض امپریالی

$$E\{[\hat{\Sigma}]\} = [\Sigma] - \frac{1}{N} [\Sigma] = \frac{N-1}{N} [\Sigma] \rightarrow \text{biased!}$$

پس برای unbiased کردن آن فرمول را کمی تغییر می دهیم

$$[\hat{\Sigma}] = \frac{1}{N-1} \sum (\underline{x}_i - \underline{m})(\underline{x}_i - \underline{m})^T$$

* تبدیل خطی

• دیت : آرایش اعداد بردار / دیت بدون یک خاصیت دیت های جدید
uncorrelated

$$\underline{y}_{m \times 1} = [a] \underline{x}_{n \times 1}$$

$$[a] \equiv n \times m$$

Subject: _____

Year: _____ Month: _____ Date: _____

$$\underline{Y} = [a]^T \underline{X}$$

$$E\{\underline{Y}\} = \underline{m}_Y = [a]^T E\{\underline{X}\}$$

$$\underline{m}_Y = [a]^T \underline{m}_X$$

$$\begin{aligned} \text{cov}\{\underline{Y}\} = [\Sigma]_Y &= E\{(\underline{Y} - \underline{m}_Y)(\underline{Y} - \underline{m}_Y)^T\} \\ &= E\{[a]^T (\underline{X} - \underline{m}_X)(\underline{X} - \underline{m}_X)^T [a]\} \\ &= [a]^T E\{-\} [a] \end{aligned}$$

$$[\Sigma]_Y = [a]^T [\Sigma]_X [a]$$

$$[\Sigma]_Y = E\{\underline{Y}\underline{Y}^T\} = [a]^T [\Sigma]_X [a]$$

$$\underline{X} = N(\underline{m}_X, [\Sigma]_X)$$

$$P(\underline{x}) = \frac{1}{(2\pi)^{n/2} |[\Sigma]|^{1/2}} \exp\{-\frac{1}{2} d^2(\underline{x})\}$$

$$d^2(\underline{x}) = (\underline{x} - \underline{m}_X)^T [\Sigma]_X^{-1} (\underline{x} - \underline{m}_X)$$


$$P(\underline{y}) = \frac{1}{|[a]| (2\pi)^{n/2} |[\Sigma]_X|^{1/2}} \exp\{-\frac{1}{2} d^2(\underline{y})\}$$

$$|[\Sigma]_Y| = |[\Sigma]_X| | [a]^T |^2$$

$$\begin{aligned} d_y^2(\underline{y}) &= (\underline{y} - \underline{m}_Y)^T [\Sigma]_Y^{-1} (\underline{y} - \underline{m}_Y) \\ &= (\underline{x} - \underline{m}_X)^T [a] [a]^T^{-1} [\Sigma]_X^{-1} ([a]^T)^{-1} [a]^T (\underline{x} - \underline{m}_X) \\ &= (\underline{x} - \underline{m}_X)^T [\Sigma]_X^{-1} (\underline{x} - \underline{m}_X) \end{aligned}$$

under linear transformation, distance is preserved.

X-Space



→ Normal Dist


→ x_1 & x_2 are correlated

linear transformation

→ y_1 & y_2 are not correlated

دقتی. مجردی یعنی مازی مجرد باشند.

Orthonormal Transformation



$$\underline{z} = \underline{x} - m_x$$


$$d_z^2 = \underline{z}^T [\Sigma]_x^{-1} \underline{z}$$

• می خواهیم بیشترین مقدار فاصله را به جهت تابع تغییر بیابیم
با این قید:

constraint: $\underline{z}^T \underline{z} = 1$

→ Lagrange multiplier

$$F = \underline{z}^T [\Sigma]_x^{-1} \underline{z} - \mu (\underline{z}^T \underline{z} - 1)$$



$$\underline{x} = x \underline{i} + y \underline{j} \quad , \quad \underline{i} = \begin{bmatrix} 1 \\ 0 \end{bmatrix} \quad , \quad \underline{j} = \begin{bmatrix} 0 \\ 1 \end{bmatrix}$$

$$\underline{i}^T \underline{j} = 0 \quad / \quad , \quad \underline{i}^T \underline{i} = 1 \quad /$$

$$\text{maximize } \Rightarrow \frac{\partial F}{\partial \underline{z}} = 2 [\Sigma]^{-1} \underline{z} - 2\mu \underline{z} = \underline{0}$$

$$\Rightarrow [\Sigma]^{-1} \underline{z} = \mu \underline{z}$$

$$\Rightarrow [\Sigma] \underline{z} = \frac{1}{\mu} \underline{z}$$

$$\Rightarrow \boxed{[\Sigma] \underline{z} = \lambda \underline{z}} \Rightarrow \begin{array}{l} \text{میشترین یا کمترین مقدار ویژه} \\ \text{در آن راست است.} \end{array}$$

$\underline{\phi}$ = eigen vector (= \underline{z})

بردار ویژه

λ = eigen value

مقدار ویژه

$$|[\Sigma]_x - \lambda [I]| = 0 \rightarrow \lambda = ? \quad (\text{مقدار ویژه}) \quad \text{معادله مشخصه}$$

$$([\Sigma]_x - \lambda [I]) \underline{\phi} = 0 \rightarrow \underline{\phi} = ? \quad (\text{بردار ویژه})$$

$\underline{\phi}_i$ = eigen vector corresponding to λ_i

$$\underline{\phi}_i^T \underline{\phi}_j^T = \begin{cases} 1 & i = j \\ 0 & i \neq j \end{cases} \iff \text{Orthogonal}$$

$$[\Sigma]_x \underline{\phi}_i = \lambda_i \underline{\phi}_i$$

$\times \underline{\phi}_j$

$$[\Sigma]_x \underline{\phi}_j = \lambda_j \underline{\phi}_j$$

$\times \underline{\phi}_i$

$$\begin{array}{l} [\Sigma] \\ \text{خطی مستقل} \end{array} \rightarrow 0 = (\lambda_i - \lambda_j) \underline{\phi}_i^T \underline{\phi}_j^T$$

$$\Rightarrow \begin{cases} i = j \rightarrow 0 \cdot (\lambda_i - \lambda_i) \underline{\phi}_i^T \underline{\phi}_i \xrightarrow{\text{مبنی نوب}} \underline{\phi}_i^T \underline{\phi}_i = 1 \\ i \neq j \rightarrow 0 \cdot (\lambda_i - \lambda_j) \underline{\phi}_i^T \underline{\phi}_j \rightarrow \underline{\phi}_i^T \underline{\phi}_j = 0 \end{cases}$$

x-Space .

Transformation Matrix $\equiv [a]$

$$[\Phi] \equiv [a] = \begin{bmatrix} \underline{\phi}_1 & \underline{\phi}_2 & \dots & \underline{\phi}_n \end{bmatrix}$$

eigen vector matrix

$$\begin{aligned} [\Phi]^T [\Phi] &= [I] \\ [\Phi]^T &= [\Phi]^{-1} \end{aligned}$$

orthogonal خاص

بردارهای ستونی / بردارهای ویژه ماتریس $[\Sigma]$

$$[\lambda] = \text{diag} \{ \lambda_1, \lambda_2, \dots, \lambda_n \}$$

$$= \begin{bmatrix} \lambda_1 & & & \\ & \lambda_2 & & \\ & & \ddots & \\ & & & \lambda_n \end{bmatrix}$$

eigen value matrix

$$\Rightarrow [\Sigma]_x \underline{x} = \lambda_i \underline{x}$$

$$\Rightarrow [\Sigma]_x [\Phi] = [\Phi] [\lambda]$$

تبدیل برای نظری کردن ماتریس .

$$\underline{y} = [a]^T \underline{x}$$

$$[\Sigma]_y = [a]^T [\Sigma]_x [a] = [\Phi]^T [\Sigma]_x [\Phi]$$

$$[\Sigma]_x [\Phi] = [\Phi] [\lambda] \xrightarrow{\times [\Phi]^T} [\Phi]^T [\Sigma]_x [\Phi] = [\lambda] \Rightarrow [\Sigma]_y = [\lambda]$$

ماتریس قطری ← داده uncorrelated

برای نظری کردن ماتریس ، ماتریس تبدیل $[a]$ باید n بردارهای ویژه ماتریس باشد $([\Phi])$.


Subject: _____

Year: _____ Month: _____ Date: _____


$$\underline{y} = [\Phi]^T \underline{x}$$

$$\underline{y} = [\underline{\phi}_1 \ \underline{\phi}_2 \ \dots \ \underline{\phi}_n]^T \underline{x}$$

$$y_i = \underline{\phi}_i^T \cdot \underline{x} = \frac{1}{\|\underline{\phi}_i\|} \|\underline{\phi}_i\| \|\underline{x}\| \cos \theta = \|\underline{x}\| \cos \theta$$



- coordinate transformation
- diagonalize $[\Sigma]$




در واقع

$$\underline{y} = [\Phi]^T \underline{x}$$

$$[\Sigma]_y = [\lambda]$$

$$\|\underline{y}\|^2 = \underline{y}^T \underline{y} = ([\Phi]^T \underline{x})^T ([\Phi]^T \underline{x}) = \underline{x}^T [\Phi] [\Phi]^T \underline{x} = \underline{x}^T \underline{x} = \|\underline{x}\|^2$$

In orthonormal transformation, distance is preserved.



Subject:

Year: Month: Date: 11

$$[\Sigma]^{-1} = [\lambda]$$

$$d^2(y) = (y - \underline{m}_y)^T [\Sigma]^{-1} (y - \underline{m}_y)$$

$$d^2(y) = \sum_{i=1}^n \frac{(y_i - m_{iy})^2}{\lambda_i} \quad (*)$$

$$d^2(y) = \frac{(y_1 - m_{1y})^2}{\lambda_1} + \frac{(y_2 - m_{2y})^2}{\lambda_2} + \dots + \frac{(y_n - m_{ny})^2}{\lambda_n} = c$$

معادله بیضی ← نظر دی بیضی معلوم است


$$[\Sigma]^{-1} = \begin{bmatrix} \frac{1}{\lambda_1} & & & \\ & \frac{1}{\lambda_2} & & \\ & & \ddots & \\ & & & \frac{1}{\lambda_n} \end{bmatrix} \Rightarrow (*)$$

$$P_y(y) = \frac{1}{(2\pi)^{n/2} |\Sigma|^{1/2}} \exp\left\{-\frac{1}{2} d^2(y)\right\} = k$$

$$[\Sigma]_x = \begin{bmatrix} 2 & -1 \\ -1 & 2 \end{bmatrix} \quad \underline{m} = \begin{bmatrix} 2 \\ 1 \end{bmatrix}$$

$$|[\Sigma] - \lambda[I]| = 0 \rightarrow \lambda_1 = 3, \lambda_2 = 1$$

$$\phi_1 = \begin{bmatrix} \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} \end{bmatrix} \quad \phi_2 = \begin{bmatrix} \frac{1}{\sqrt{2}} \\ -\frac{1}{\sqrt{2}} \end{bmatrix}$$



$$([\Sigma] - \lambda_1[I])\phi_1 = \left(\begin{bmatrix} 2 & -1 \\ -1 & 2 \end{bmatrix} - \begin{bmatrix} 1 & 0 \\ 0 & 1 \end{bmatrix}\right)\phi_1 = \begin{bmatrix} 1 & -1 \\ -1 & 1 \end{bmatrix}\phi_1 = \begin{bmatrix} 0 \\ 0 \end{bmatrix}$$

$$\phi_1 = \begin{bmatrix} a \\ b \end{bmatrix} \Rightarrow \begin{cases} a - b = 0 \Rightarrow a = b \\ -a + b = 0 \end{cases} \Rightarrow \text{برای پیدا کردن } \phi_1 \text{ برابر 1 شد}$$

آن زمان می بینیم

PAPCO

$$\Rightarrow \phi_1 = \begin{bmatrix} \frac{a}{\sqrt{a^2+b^2}} \\ \frac{b}{\sqrt{a^2+b^2}} \end{bmatrix} = \begin{bmatrix} \frac{a}{\sqrt{2a^2}} \\ \frac{b}{\sqrt{2a^2}} \end{bmatrix} = \begin{bmatrix} \frac{1}{\sqrt{2}} \\ \frac{1}{\sqrt{2}} \end{bmatrix}$$

Whitening Transformation *

$$\underline{y} = [\underline{a}]^T \underline{x}$$

$$[\underline{\Sigma}]_y = [\underline{I}]$$

$$[\underline{a}] = [\underline{\phi}][\underline{\lambda}]^{-1/2}$$

$[\underline{\phi}]$ = eigen vector matrix of $[\underline{\Sigma}]_x$

$[\underline{\lambda}]$ = eigen value matrix of $[\underline{\Sigma}]_x$


$$[\underline{\Sigma}]_y = [\underline{a}]^T [\underline{\Sigma}]_x [\underline{a}]$$

$$= ([\underline{\phi}][\underline{\lambda}]^{-1/2})^T [\underline{\Sigma}]_x ([\underline{\phi}][\underline{\lambda}]^{-1/2})$$

$$= [\underline{\lambda}]^{-1/2} [\underline{\phi}]^T [\underline{\Sigma}]_x [\underline{\phi}] [\underline{\lambda}]^{-1/2}$$

$$= [\underline{\lambda}]^{-1/2} [\underline{\lambda}] [\underline{\lambda}]^{-1/2}$$

$$= [\underline{I}]$$



I. Whitening transformation is not orthonormal transformation

$$\text{orthonormal} \iff [\underline{a}]^T [\underline{a}] = [\underline{I}]$$

$$([\underline{\phi}][\underline{\lambda}]^{-1/2})^T ([\underline{\phi}][\underline{\lambda}]^{-1/2}) = [\underline{\lambda}]^{-1/2} [\underline{\phi}]^T [\underline{\phi}] [\underline{\lambda}]^{-1/2} = [\underline{\lambda}] \neq [\underline{I}]$$

II. Euclidean distance is not preserved.

$$\|\underline{y}\|^2 = \underline{y}^T \underline{y} = \underline{x}^T [\underline{\phi}][\underline{\lambda}]^{-1} [\underline{\phi}]^T \underline{x} = \underline{x}^T [\underline{\Sigma}]_x \underline{x} \neq \|\underline{x}\|^2$$

III. After a whitening transformation, the covariance matrix is invariant under any orthonormal transformation.

$$y = [a]^T x$$

$$[\Sigma] y = [I]$$

→ whitening transformation

$$z = [a]^T y$$

$$[\Sigma] z = [I]$$

→ orthonormal transformation

if $[Y] \equiv$ orthonormal transformation matrix

$$[Y]^T [\Sigma] y [Y] = [I]$$

Simultaneous Diagonalization

تکلی کردن همزمان

$$[\Sigma]_1 \rightarrow [I]$$

$$[\Sigma]_2 \rightarrow [I]$$

1. Find eigen value matrix and eigen vector matrix of $[\Sigma]_1$, then apply whitening transformation

$$[\Phi] \equiv \text{eigen vector of } [\Sigma]_1$$

$$[\mu] \equiv \text{eigen value of } [\Sigma]_1$$

$$y = [a]^T x$$

$$[a] = [\Phi][\mu]^{-1/2}$$

$$[\mu]^{-1/2} [\Phi]^T [\Sigma]_1 [\Phi][\mu]^{-1/2} = [I]$$

$$[\mu]^{-1/2} [\Phi]^T [\Sigma]_2 [\Phi][\mu]^{-1/2} = [K]$$

$[K]$ is not diagonal in general

2. Find eigen value matrix & eigen vector matrix of $[K]$

$$z = [a]_2^T y$$

$$[a]_2^T \equiv [\Psi] \equiv \text{eigen vector matrix of } [K]$$


$$[\lambda] \equiv \text{eigen value matrix of } [K]$$

Subject :

Year. Month. Date. ()

$$[\Psi][\Sigma]_1[\Psi]^T = [\Psi]^T[I][\Psi] = [I]$$

$$[\Psi][\Sigma]_2[\Psi]^T = [\Psi]^T[\Lambda][\Psi] = [\Lambda]$$



• تبدیل های نظری سازی برینان


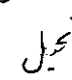
Theorem :

$$[\Sigma]_1 \longrightarrow [I]$$

$$[\Sigma]_2 \longrightarrow [\Lambda] = \text{diagonal } \{ \lambda_1, \dots, \lambda_n \}$$

eigen vector matrix $([\Sigma]_1^{-1} \quad [\Sigma]_2) \equiv [a] \rightarrow$ تبدیل های نظری سازی برینان

eigen value matrix $([\Sigma]_1^{-1} \quad [\Sigma]_2) \equiv [\lambda]$

۲ - ۵ - ۴ - ۳ - ۲ - ۱ : بردارهای کامپیوتری 
 ۱۰ - ۷ - ۶ - ۵ - ۴ - ۳ - ۲ - ۱ : سن
 ۱۷ ، ۷ ، ۲۳ : استهلاک جهت اضافی 


Subject:

Year: Month: Date: 13

Decision Function

تدريج تقسيم

(Discriminate Functions) تدريج نمايز



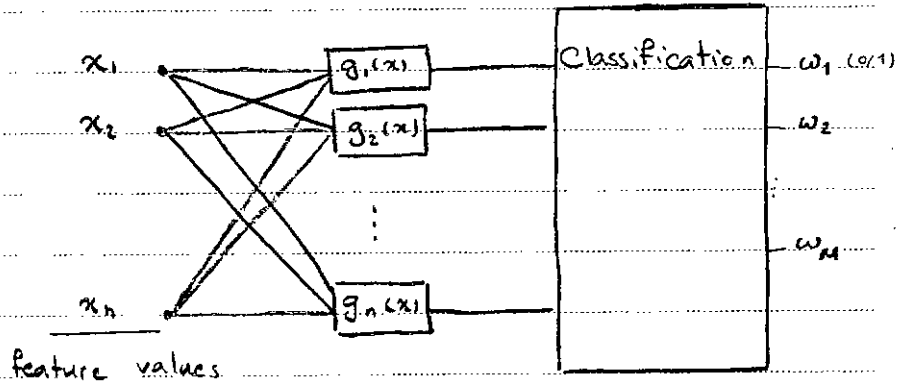
$$d(x) = a_1 x_1 + a_2 x_2 + a_0$$

$$= w_1 x_1 + w_2 x_2 + w_0 = W^T x$$

$$\left. \begin{array}{l} d(x) > 0 \quad \text{belong } \omega_1 \\ d(x) < 0 \quad \text{belong } \omega_2 \end{array} \right\} \Rightarrow d(x) \begin{array}{l} \omega_1 \\ \omega_2 \end{array} \text{ } \circ$$

2-class problem

M - class problem



Indeterminant Region, IR

Subject:

Year. Month. Date. ()

Subject :

Year . Month . Date . 144

$\underline{x} \in \omega_i$

M-Class Problem • Z

$$d_i(\underline{x}) = \begin{cases} > 0 & \underline{x} \in \omega_i \\ < 0 & \text{o.w.} \end{cases}$$

• II جابردن کلاس از کلاس j

$$\binom{M}{2} = \frac{M(M-1)}{2}$$

$\underline{x} \in \omega_i$

$$d_{ij}(\underline{x}) = \begin{cases} > 0 & \underline{x} \in \omega_i \\ < 0 & \underline{x} \in \omega_j \end{cases}$$

$$d_{ij}(\underline{x}) = -d_{ji}(\underline{x})$$

$$d_{12}(\underline{x}) = -x_1 - x_2 + 5$$

$$d_{13}(\underline{x}) = -x_1 + 3$$


$$d_{23}(\underline{x}) = -x_1 + x_2$$

$$\text{class I : } d_{12}(\underline{x}) > 0, d_{13}(\underline{x}) > 0$$

$$\text{class II : } d_{21}(\underline{x}) > 0, d_{23}(\underline{x}) > 0$$

$$\text{class III : } d_{31}(\underline{x}) > 0, d_{32}(\underline{x}) > 0$$

$$\text{class IV : } \mathbb{R} \begin{cases} d_{32}(\underline{x}) > 0, d_{31}(\underline{x}) < 0 \\ d_{21}(\underline{x}) > 0, d_{23}(\underline{x}) < 0 \\ d_{13}(\underline{x}) > 0, d_{12}(\underline{x}) < 0 \end{cases}$$



• II کلاس

M Decision Function

Subject :

Year. Month. Date. ()

i^{th} class : $d_i(\underline{x}) = \underline{w}_i^T \underline{x}$ > linear function.

$\underline{x} \in \omega_i$ $d_i(\underline{x}) > d_j(\underline{x}) \quad \forall j \neq i$
نزدیکی ندارد d عددی مثبت باشد.

$$d_{ij}(\underline{x}) = d_i(\underline{x}) - d_j(\underline{x}) > 0 \\ = \underline{w}_i^T \underline{x} - \underline{w}_j^T \underline{x} = (\underline{w}_i - \underline{w}_j)^T \underline{x} = \underline{w}_{ij}^T \underline{x}$$

$$d_1(\underline{x}) = -x_1 + x_2$$


$$d_2(\underline{x}) = x_1 + x_2 - 1$$

$$d_3(\underline{x}) = -x_2$$

$$w_1 : d_1 > d_2, d_1 > d_3$$

$$w_2 : d_2 > d_3, d_2 > d_1$$

$$w_3 : d_3 > d_1, d_3 > d_2$$



ممکن این روش است که IR وجود ندارد. هر تاشی که روی مرز قرار دارند

Classifiers

*

Minimum Distance Classifier

 \underline{x} unknown vector \underline{z}_k = representative of w_k

$$D(\underline{x}, w_k) = D(\underline{x}, \underline{z}_k)$$

$$1 \quad \text{دوری اقلیتی} = \|\underline{x} - \underline{z}\| = \sqrt{(x_1 - z_1^k)^2 + \dots + (x_n - z_n^k)^2}$$

$$\text{city block} \quad \text{دوری} = \sum |x_i - z_i| \rightarrow \text{مقدارهای مطلق}$$

$$D^2(\underline{x}, \underline{z}) = (x_1 - z_1^k)^2 + \dots + (x_n - z_n^k)^2 \\ = \sum_{i=1}^n (x_i - z_i^k)^2$$

 $D^2(\underline{x}, \underline{z}_k)$ Distance between \underline{x} & w_k

$$= \|\underline{x} - \underline{z}_k\|^2$$

$$= (\underline{x} - \underline{z}_k)^T (\underline{x} - \underline{z}_k)$$

$$= \underline{x}^T \underline{x} - \underline{x}^T \underline{z}_k - \underline{z}_k^T \underline{x} + \underline{z}_k^T \underline{z}_k$$

$$= \underline{x}^T \underline{x} - 2 \underline{x}^T \underline{z}_k + \underline{z}_k^T \underline{z}_k$$

Classifier: $\underline{x} \in w_k$ if

$$D^2(\underline{x}, w_k) = \min_{\forall i} \left[\underline{x}^T \underline{x} - 2 \underline{x}^T \underline{z}_i + \underline{z}_i^T \underline{z}_i \right]$$

این جمله همیشه مثبت است، پس آنرا حذف می کنیم، در حد استناد تابع ظاهر می شود.

$$D^2(\underline{x}, w_k) = \min [-2 \underline{x}^T \underline{z}_i + \underline{z}_i^T \underline{z}_i]$$

$$= \max [2 \underline{x}^T \underline{z}_i - \underline{z}_i^T \underline{z}_i]$$

$$d_k(\underline{x}) = \underline{x}^T \underline{z}_k - \frac{1}{2} \underline{z}_k^T \underline{z}_k$$

Subject:

Year:

Month:

Date:

()

$$\underline{x} \in \omega_k \quad d_k(\underline{x}) > d_j(\underline{x}) \quad \forall j \neq k$$

$$d_{kj}(\underline{x}) = d_k(\underline{x}) - d_j(\underline{x})$$

یادآوری: نتایج فصل دوم (موضوعی) n بعدی 

$$\underline{x} = \begin{bmatrix} x_1 \\ \vdots \\ x_n \end{bmatrix} \Rightarrow \underline{x}' = \begin{bmatrix} 1 \\ x_1 \\ \vdots \\ x_n \end{bmatrix}$$

$$\underline{w} = \begin{bmatrix} w_1 \\ \vdots \\ w_n \end{bmatrix} \Rightarrow \underline{w}' = \begin{bmatrix} w_0 \\ w_1 \\ \vdots \\ w_n \end{bmatrix}$$

$$d(\underline{x}) = w_1 x_1 + w_2 x_2 + \dots + w_n x_n + w_0$$

$$= \sum_{i=1}^n w_i x_i + w_0$$

$$= \underline{w}'^T \underline{x}'$$

$$d_k(\underline{x}) = \underline{x}^T \underline{z}_k - \frac{1}{2} \underline{z}_k^T \underline{z}_k$$

$$d(\underline{x}) = \underline{w}'^T \underline{x}'$$

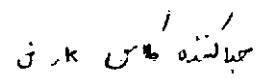
weight ↙ ↘

$$\underline{w} = \underline{z}$$

$$w_0 = -\frac{1}{2} \underline{z}_k^T \underline{z}_k$$

$$d_k(\underline{x}) = \underline{w}_k^T \underline{x} = \underline{x}^T \underline{z}_k - \frac{1}{2} \underline{z}_k^T \underline{z}_k$$

$$d_{kj}(\underline{x}) = d_k(\underline{x}) - d_j(\underline{x})$$


میانگین ک و ج 

$$= \underline{x}^T (\underline{z}_k - \underline{z}_j) - \frac{1}{2} (\underline{z}_k^T \underline{z}_k - \underline{z}_j^T \underline{z}_j)$$


$$= \underline{x}^T (\underline{z}_k - \underline{z}_j) - \frac{1}{2} (\underline{z}_k - \underline{z}_j)^T (\underline{z}_k + \underline{z}_j)$$

Subject:

Year. Month. Date. 16



این تقسیم‌بندی عمود منصف دارد خطی است که در فاصله z_k و z_j قرار دارد. می‌کند. z_k نماینده یک کلاس است و معمولاً میانگین کلاس است.



اگر داده uni-Model باشند، این classifier بهترین انتخاب است.


اگر بجای یک نماینده، M نماینده از هر کلاس موجود باشد.

$$D(x, w_k) = \min_{m=1, \dots, N_k} \left[D(x, z_k^{(m)}) \right]$$

k^{th} class is represented by N_k representatives (prototypes).

$$d_k(x) = \max_{m=1, \dots, N_k} \left[x^T z_k^{(m)} - \frac{1}{2} |z_k^{(m)}|^2 \right]$$

$k = 1, \dots, M \sim \# \text{ of classes}$



$x \in z_1$

$x \in z_1$

Subject :


Year . Month . Date . ()

آیا داده به خطی جدا پذیر هستند؟
 اگر داده دایب مجانب convex نیستند
 تقابلی زیادی وجود دارند
 اگر داده دارای توزیع نرمال باشند ✓

Generalized Decision Function

$$d(x) = W_1 f_1(x) + W_2 f_2(x) + \dots + W_k f_k(x)$$


$$= \sum_{i=1}^k W_i f_i(x)$$



2-D

$$d(x) = W_{11} x_1^2 + W_{22} x_2^2 + W_{12} x_1 x_2 + W_{21} x_2 x_1 + W_1 x_1$$

$$+ W_2 x_2 + W_0$$



$$\begin{matrix} x_1^2 \rightarrow f_1(x) \\ x_2^2 \rightarrow f_2(x) \\ x_1 x_2 \rightarrow f_3(x) \\ \vdots \\ f_k(x) \\ -1 \end{matrix} \Rightarrow \underline{x}^* = \begin{bmatrix} f_1(x) \\ f_2(x) \\ \vdots \\ f_k(x) \\ -1 \end{bmatrix}$$

$W_0 \leftarrow$

n-D : Quadratic

$$d(x) = \underbrace{\sum_{j=1}^n W_{jj} x_j^2}_{n} + \underbrace{\sum_{j=1}^{n-1} \sum_{k=j+1}^n W_{jk} x_j x_k}_{\frac{n(n-1)}{2}} + \underbrace{\sum_{j=1}^n W_j x_j}_n + W_{n+1}$$

$\frac{(n+1)(n+2)}{2} =$ تعداد فریب ←

$$N_w = \frac{(n+r)!}{r! n!} \quad ; \quad r\text{-order}, n\text{-D} \quad \text{طرز جدایی}$$

Subject:

Year. Month. Date. FA

$$n=2 \quad r=2 \quad Nw=6$$

$$n=3 \quad r=2 \quad Nw=10$$

$$n=3 \quad r=4 \quad Nw=35$$

$$d(\underline{x}) = \underline{x}^T [A] \underline{x} + \underline{x}^T \underline{b} + c$$

$$\underline{x} = \begin{bmatrix} x_1 \\ \vdots \\ x_n \end{bmatrix}$$

$$[A] = (a_{jk}) \Rightarrow \begin{cases} w_{jj} = a_{jj} & j=1, \dots, n \\ w_{jk} = 2a_{jk} & j=k, \dots, n \quad i \neq k \\ w_j = b_j \\ w_{n+1} = c \end{cases}$$

$$\star [A] = [I] \Rightarrow \text{hyper sphere}$$

$$\star [A] > 0 \Rightarrow \text{hyper elepsoid}$$

$$\star [A] \geq 0 \Rightarrow \text{hyper elepsoid cylenderical}$$

Subject:

Year:

Month:

Date:

()

Statistical Discriminant Function

* تراجم گمانی آماری :

Hypothesis Test for 2-Class

Bayes Eq. → احتمال

$$P(w_i | x) \equiv q_i(x) = \frac{P_i \cdot P_i(x)}{P(x)}$$

$P_i \equiv P(w_i) \equiv \text{Prob} \{w_i\}$ $i = 1, 2$ → احتمال اولیه prior: prob. of w_i .

$P_i(x) = P(x | w_i)$ → تابع گمانی احتمال شرطی برای w_i

$P(x) = \sum_{i=1}^{M=2} P_i \cdot P_i(x)$ → تابع گمانی احتمال کلی

Bayes Classifier:

x unknown

$$q_1(x) \begin{matrix} \nearrow \omega_1 \\ \searrow \omega_2 \end{matrix} q_2(x) \quad \text{I.}$$

$$\frac{P_1 \cdot P_1(x)}{P(x)} \begin{matrix} \nearrow \omega_1 \\ \searrow \omega_2 \end{matrix} \frac{P_2 \cdot P_2(x)}{P(x)} \Rightarrow P_1 \cdot P_1(x) \begin{matrix} \nearrow \omega_1 \\ \searrow \omega_2 \end{matrix} P_2 \cdot P_2(x) \quad \text{II.}$$

$$l(x), \text{ Likelihood function} = \frac{P_1(x)}{P_2(x)} \Rightarrow l(x) \begin{matrix} \nearrow \omega_1 \\ \searrow \omega_2 \end{matrix} \frac{P_2}{P_1} \dots \text{threshold III.}$$

$$h(x) = -\ln l(x) = \ln P_2(x) - \ln P_1(x) \begin{matrix} \nearrow \omega_2 \\ \searrow \omega_1 \end{matrix} \ln \left(\frac{P_1}{P_2} \right) \quad \text{IV.}$$

↳ statistical discriminant function

Subject:

Year:

Month:

Date:

18

X with binary valued elements & independent ✓

$$\underline{x} = [x_1 \dots x_n]^T$$

2-class problem

$$\text{Prob} \{x_i = 1 \mid \omega_1\} = P_i'$$

$$\text{Prob} \{x_i = 0 \mid \omega_1\} = 1 - P_i'$$

$$\text{Prob} \{x_i = 1 \mid \omega_2\} = q_i'$$

$$\text{Prob} \{x_i = 0 \mid \omega_2\} = 1 - q_i'$$

$$P(\underline{x} \mid \omega_i) = P(x_1 \mid \omega_i) \cdot P(x_2 \mid \omega_i) \cdot \dots \cdot P(x_n \mid \omega_i)$$

$$P(\underline{x} \mid \omega_1) = \prod_{i=1}^n (P_i')^{x_i} (1 - P_i')^{1-x_i}$$

$$P(\underline{x} \mid \omega_2) = \prod_{i=1}^n (q_i')^{x_i} (1 - q_i')^{1-x_i}$$

$$L(\underline{x}) = \frac{P_1(\underline{x})}{P_2(\underline{x})} = \frac{\prod_{i=1}^n (P_i')^{x_i} (1 - P_i')^{1-x_i}}{\prod_{i=1}^n (q_i')^{x_i} (1 - q_i')^{1-x_i}} \begin{matrix} \omega_1 \\ \omega_2 \end{matrix} \frac{P_2}{P_1}$$

$$\ln L(\underline{x}) = \ln \frac{P_1(\underline{x})}{P_2(\underline{x})} = \sum [\alpha_i \ln \frac{P_i'}{q_i'} + (1 - \alpha_i) \ln \frac{1 - P_i'}{1 - q_i'}] + \ln \frac{P_1}{P_2}$$

$$h(\underline{x}) = \sum_{i=1}^n \left[x_i \ln \frac{P_i' (1 - q_i')}{q_i' (1 - P_i')} + \ln \frac{1 - P_i'}{1 - q_i'} \right] + \ln \frac{P_1}{P_2}$$

o o o

$$\underline{x} = \begin{bmatrix} 1 \\ x_1 \\ \vdots \\ x_n \end{bmatrix} \xrightarrow{d(\underline{x}) = \underline{w}^T \underline{x}} \underline{w} = \begin{bmatrix} w_0 \\ w_1 \\ \vdots \\ w_n \end{bmatrix} \rightarrow \text{augmented weight vector}$$

$$h(\underline{x}) = \underline{w}^T \underline{x} = \sum_{i=1}^n x_i \cdot w_i + w_0 \begin{matrix} \omega_1 \\ \omega_2 \end{matrix} \circ$$

Subject:

Year. Month. Date. ()

\underline{X} with 3-valued elements & independent

$$\alpha_i = 1, 0, -1$$

$$h(\underline{x}) = ?$$

2-class problem

$$\underline{X} = \begin{bmatrix} x \\ y \end{bmatrix} \quad \underline{m}_x = \begin{bmatrix} m_x \\ m_y \end{bmatrix}$$

$$[\Sigma]_x = \begin{bmatrix} \sigma_x^2 & \rho_{xy} \cdot \sigma_x \cdot \sigma_y \\ \rho_{xy} \cdot \sigma_y \cdot \sigma_x & \sigma_y^2 \end{bmatrix}$$

$$\underline{X} \sim N(\underline{m}, [\Sigma])$$

$$|\Sigma| = \sigma_x^2 \sigma_y^2 (1 - \rho_{xy}^2)$$

$$P(x, y | \omega_i) = \frac{1}{2\pi \sigma_x \sigma_y \sqrt{1 - \rho_{xy}^2}} \exp \left\{ \frac{-1}{2(1 - \rho_{xy}^2)} \left[\frac{(x - m_x)^2}{\sigma_x^2} + \frac{(y - m_y)^2}{\sigma_y^2} - \frac{2 \rho_{xy} (x - m_x)(y - m_y)}{\sigma_x \sigma_y} \right] \right\}$$

$$d(\underline{x}) = (\underline{x} - \underline{m}_x)^T [\Sigma]_x^{-1} (\underline{x} - \underline{m}_x)$$

$$P_1 = P(\omega_1) = 0.8$$

$$P_2 = P(\omega_2) = 0.2$$

$$\underline{m}_1 = \begin{bmatrix} 26 \\ 85 \end{bmatrix}$$

$$\underline{m}_2 = \begin{bmatrix} 22 \\ 70 \end{bmatrix}$$

$$\rho_{xy}^1 = 0.6$$

$$\rho_{xy}^2 = 0.5$$

$$[\Sigma]_1 = \text{cov} \{ \underline{X} | \omega_1 \} = \begin{bmatrix} 4 & 6 \\ 6 & 25 \end{bmatrix}$$


$$[\Sigma]_2 = \begin{bmatrix} 9 & 12 \\ 12 & 64 \end{bmatrix}$$

$$h(\underline{x}) = -5.819 x^2 + 3.167 xy$$

$$- y^2 + 41.89 x$$

$$+ 27.30 y - 5940$$

class prob




Subject:

Year: Month: Date: 19

$$\sigma_{1x} = \sigma_{2x}$$



$$\sigma_{1y} > \sigma_{2y}$$

$$\rho_{12} = \rho_{21} = 0$$



$$\frac{\sigma_{1x}}{\sigma_{2x}} = \frac{\sigma_{1y}}{\sigma_{2y}}$$

$$\rho_{12} = \rho_{21} = 0$$



$h(x) \sim$ parabolic

$h(x) \sim$ ellipsoid


$h(x) \sim$ hyperbolic

1-D

2-class problem

انواع خطای طبقه بندی 1 و 2

خطای 1 و 2



E_2 Probability of Error

$$P_1 P_1(x) \sum_{w_2} P_2 P_2(x)$$

انتقال n -بسی

$$E_2 = \int_{R_2} P_1 \cdot P_1(x) \cdot dx + \int_{R_1} P_2 \cdot P_2(x) \cdot dx$$

$$= P_1 \int_{R_2} P_1(x) \cdot dx + P_2 \int_{R_1} P_2(x) \cdot dx$$

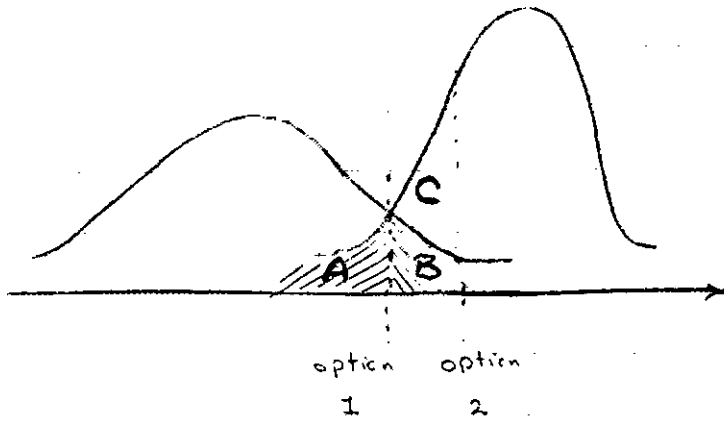
$$= P_1 E_1 + P_2 E_2$$

Subject:

Year: Month: Date: ()

$$h(x) = -\ln L(x) = \sum_{\omega_i} w_i \cdot \phi$$

تایید بایس ، عملیاتی نوع توزیع مرز تقسیم لری هستند
این نوع بکینه است. چون:



option 1: $E = A+B$

option 2: $E = A+B+C$

option 1 $\checkmark \Rightarrow$ Bayes \checkmark

این قضیه را با با الهی اثبات نماید.

$$h(x) = -\ln L(x) = \ln P_2(x) - \ln P_1(x) = \sum_{\omega_i} \ln \frac{P_1}{P_2}$$


$h(x) \rightarrow$ Random Variable

با محاسبه سطحی $h(x)$ می توان سطحی چندوجهی $L(x)$ را یک جدیت w

$$E = P_1 \int_{R_1} P_H(h | \omega_1) \cdot h + P_2 \int_{R_2} P_H(h | \omega_2) \cdot h$$

\rightarrow انزال بعدی

تست دشوار این مسئله ، همین نوع $h(x)$ است.



Subject:

Year: Month: Date: 20

$$l(x) = \frac{P_1(x)}{P_2(x)} \begin{matrix} \omega_1 \\ \omega_2 \end{matrix} \frac{P_2}{P_1}$$

$$h(x) = -\ln l(x) = \ln P_2(x) - \ln P_1(x) \begin{matrix} \omega_2 \\ \omega_1 \end{matrix} \ln \frac{P_1}{P_2}$$


$$\omega_1 = N(\underline{m}_1, [\Sigma]_1) \quad P_1 \quad \checkmark$$

$$\omega_2 = N(\underline{m}_2, [\Sigma]_2) \quad P_2$$

$n = D$, 2-class Problem

$$P_i(x) = \frac{1}{(2\pi)^{n/2} |[\Sigma]_i|^{1/2}} \exp \left\{ -\frac{1}{2} (x - \underline{m}_i)^T [\Sigma]_i^{-1} (x - \underline{m}_i) \right\} \quad i=1,2$$

$$h(x) = -\ln l(x) = \frac{1}{2} (x - \underline{m}_1)^T [\Sigma]_1^{-1} (x - \underline{m}_1) - \frac{1}{2} (x - \underline{m}_2)^T [\Sigma]_2^{-1} (x - \underline{m}_2) + \frac{1}{2} \ln \frac{|[\Sigma]_1|}{|[\Sigma]_2|} \begin{matrix} \omega_2 \\ \omega_1 \end{matrix} \ln \frac{P_1}{P_2}$$



فرم تابع زینال با دو پارامتر یعنی \underline{m} و $[\Sigma]$

شکل تابع جداکننده درجه 2 است.

$$* S_1 \quad [\Sigma]_1 = [\Sigma]_2 = [\Sigma]$$

$$h(x) = (\underline{m}_2 - \underline{m}_1)^T [\Sigma]^{-1} x + \frac{1}{2} (\underline{m}_1^T [\Sigma]^{-1} \underline{m}_1 - \underline{m}_2^T [\Sigma]^{-1} \underline{m}_2) \begin{matrix} \omega_2 \\ \omega_1 \end{matrix} \ln \frac{P_1}{P_2}$$

$$h(x) = \underline{w}^T x + \omega_c$$


تابع خطی

Subject:

Year:

Month:

Date:



$$\Sigma_1 = \Sigma_2$$

Special Case

$$\underline{m}_i = \underline{0}$$

$i = 1, 2$

$$[\Sigma]_i = \begin{bmatrix} 1 & \rho_i & \rho_i^2 & \dots & \rho_i^{n-1} \\ \rho_i & 1 & \rho_i & \dots & \rho_i^{n-2} \\ \rho_i^2 & \rho_i & 1 & \dots & \rho_i^{n-3} \\ \vdots & \vdots & \vdots & \ddots & \vdots \\ \rho_i^{n-1} & \rho_i^{n-2} & \rho_i^{n-3} & \dots & 1 \end{bmatrix}$$

→ toeplitz matrix → 1 طرفی

→ ρ_i = correlation coefficient of random variables for i^{th} class

$$c_{ij} = \rho_{ij} \cdot \sigma_i \cdot \sigma_j$$

خاص ماتریس

toeplitz

$$[\Sigma]_i^{-1} = \frac{1}{1 - \rho_i^2} \begin{bmatrix} 1 & -\rho_i & 0 & \dots & 0 \\ -\rho_i & 1 + \rho_i^2 & -\rho_i & \dots & 0 \\ 0 & -\rho_i & 1 + \rho_i^2 & \dots & \vdots \\ \vdots & \vdots & \vdots & \ddots & -\rho_i \\ 0 & 0 & \dots & -\rho_i & 1 + \rho_i^2 \end{bmatrix}$$

$$|\Sigma| = (1 - \rho_i^2)^{n-1}$$

$$h(\underline{x}) = \ln l(\underline{x}) = \left(\frac{1 + \rho_1^2}{1 - \rho_1^2} - \frac{1 + \rho_2^2}{1 - \rho_2^2} \right) \sum_{i=1}^n x_i^2 - \left(\frac{\rho_1^2}{1 - \rho_1^2} - \frac{\rho_2^2}{1 - \rho_2^2} \right) (x_1^2 + x_n^2)$$

$$- \left(\frac{2\rho_1}{1 - \rho_1^2} - \frac{2\rho_2}{1 - \rho_2^2} \right) \sum_{i=1}^{n-1} x_i x_{i+1}$$

$$+ (n-1) \ln \frac{1 - \rho_1^2}{1 - \rho_2^2} \quad \text{or} \quad \ln \frac{1 - \rho_1^2}{1 - \rho_2^2}$$

Subject:

Year. Month. Date. 21

$$h(x) = \frac{\sum_{i=1}^n x_i \cdot x_{i+1}}{\sum_{i=1}^n x_i^2} \gg t$$

عامل تعیین کننده تائید ، Covariance مستند

* احتمال دادن برینه در طبقه بندی

C_{12} = cost of deciding $x \in \omega_2$ when $x \in \omega_1$ → wrong decision


C_{11} = cost of deciding $x \in \omega_1$ when $x \in \omega_1$

C_{21} = cost of deciding $x \in \omega_1$ when $x \in \omega_2$ → wrong decision

C_{22} = cost of deciding $x \in \omega_2$ when $x \in \omega_2$

C_{ij} → i : true class j : decision

$C_{12} > C_{11}$ و $C_{21} > C_{22}$ → خط برینه بابت



$r = E\{cost\}$ → To minimize ...

$$r = \int_{R_1} C_{11} P_1 P_1(x) dx + \int_{R_2} C_{12} P_1 P_1(x) dx + \int_{R_1} C_{21} P_2 P_2(x) dx + \int_{R_2} C_{22} P_2 P_2(x) dx$$

$$= \int_{R_1} \{C_{11} P_1 P_1(x) + C_{21} P_2 P_2(x)\} dx + \int_{R_2} \{C_{12} P_1 P_1(x) + C_{22} P_2 P_2(x)\} dx$$

$$\textcircled{1} = \int_{R_2} P_1(x) dx = 1 - \int_{R_1} P_1(x) dx$$

Subject:

Year: _____

Month: _____

Date: _____

$$\textcircled{2} = c_{12} P_1 \left[1 - \int_{R_1} P_1(x) dx \right] + c_{22} P_2 \left[1 - \int_{R_2} P_2(x) dx \right]$$

$$r: c_{12} P_1 + c_{22} P_2 + \int_{R_1} \left\{ -(c_{12} - c_{11}) P_1(x) + (c_{21} - c_{22}) P_2(x) \right\} dx$$

etc etc > 0

$$g(x) > 0$$

r → to be minimized ⇒ g → to be minimized


$$r = \arg \min \left\{ \int_{R_1} g(x) dx \right\}$$

$$\exists x \Rightarrow g(x) < 0 \longrightarrow x \in \omega_1 \checkmark$$

$$(c_{12} - c_{11}) P_1(x) \int_{\omega_1} (c_{21} - c_{22}) P_2(x)$$

$$g(x) = \frac{P_1(x)}{P_2(x)} \cdot \frac{P_2(c_{21} - c_{22})}{P_1(c_{12} - c_{11})}$$

- threshold



Subject: _____

Year: _____ Month: _____ Date: 22

1-D 2-class Problem ☑

$$P(x|w_1) = \frac{1}{\sqrt{2\pi} \sqrt{3}} e^{-\frac{1}{2} \left(\frac{x^2}{3}\right)}$$

$$E\{X|w_1\} = 0$$

$$\text{var}\{X|w_1\} = 3$$

$$P(x|w_2) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}(x-2)^2}$$

$$E\{X|w_2\} = 2$$

$$\text{var}\{X|w_2\} = 1$$

$$P_1 = P_2 = \frac{1}{2}$$

$$C_{11} = C_{22} = 0$$


$$C_{21} = 1$$

$$C_{12} = \sqrt{3}$$

$$L(x) = \frac{P_1(x)}{P_2(x)} = \frac{e^{-\frac{1}{2} \frac{x^2}{3}}}{e^{-\frac{1}{2}(x-2)^2}} \begin{matrix} w_1 \\ \swarrow \\ \searrow \\ w_2 \end{matrix} \begin{matrix} 1 \\ \\ \\ 0 \end{matrix}$$

$$\xrightarrow{\ln} -\frac{1}{2} \frac{x^2}{3} + \frac{1}{2}(x-2)^2 \begin{matrix} w_1 \\ \swarrow \\ \searrow \\ w_2 \end{matrix} \begin{matrix} 0 \\ \\ \\ 0 \end{matrix} \rightarrow 2x^2 - 12x + 12 \begin{matrix} w_1 \\ \swarrow \\ \searrow \\ w_2 \end{matrix} \begin{matrix} 0 \\ \\ \\ 0 \end{matrix}$$

$$\rightarrow x_1 = 4.73, x_2 = 1.27$$



The Neyman - Pearson Test

انواع مختلفہ در تقسیم گیری

$$E_1 = \int_{R_2} P_1(x) \cdot dx$$

$$E_2 = \int_{R_2} P_2(x) \cdot dx$$

سوال

$$\text{مطلوبہ: } E_2 \geq E_0 \rightarrow E_1 \text{ minimize}$$

Minimize E_1 subject to $E_2 \geq E_0$

$$\text{Lagrangian: } L = E_1 + \lambda (E_2 - E_0)$$

Subject:

Year:

Month:

Date: ()

$$r = E_1 + H(E_2 - E_0)$$

$$= \int_{R_2} P_1(x) dx + H \left\{ \int_{R_1} P_2(x) dx - E_0 \right\}$$

$$= \underbrace{(1-H)E_0}_{etc} + \int_{R_1} (\mu P_2(x) - P_1(x)) dx$$


تعداد بیشتره کینه بران $\rightarrow < 0 \Rightarrow \omega_1$

$$P_1(x) \begin{matrix} \omega_1 \\ \omega_2 \end{matrix} \mu P_2(x) \rightarrow \left| \frac{e(x) \cdot P_1(x)}{P_2(x)} \begin{matrix} \omega_1 \\ \omega_2 \end{matrix} \mu \right|$$

Lagrange Multiplier $\leftarrow \mu$ کینه

$$E_2 = \int_{R_1} P_2(x) dx = E_0 \rightarrow etc$$

$$E_2 = \int_{-\infty}^{\infty} P_H(h | \omega_2) dh = E_0$$



\leftarrow با تغییر μ می توان E_0 را بدست آورد.

2-D

2 - Normally Distributed Class

$$\underline{m}_1 = \begin{bmatrix} -1 \\ 0 \end{bmatrix}$$

$$\underline{m}_2 = \begin{bmatrix} 1 \\ 0 \end{bmatrix}$$

$$[\Sigma]_1 = [\Sigma]_2 = [1]$$

$$P_1 = P_2 = \frac{1}{2}$$


$$[\Sigma]_1 = [\Sigma]_2 \Rightarrow h(x) = (\underline{m}_2 - \underline{m}_1)^T [\Sigma]^{-1} x + \frac{1}{2} (\underline{m}_1^T [\Sigma]^{-1} \underline{m}_1 - \underline{m}_2^T [\Sigma]^{-1} \underline{m}_2) \geq \ln \frac{P_1}{P_2}$$

$$e(x) \cdot \frac{P_1(x)}{P_2(x)} \begin{matrix} \omega_1 \\ \omega_2 \end{matrix} \mu \Rightarrow h(x) = \left(\begin{bmatrix} 1 \\ 0 \end{bmatrix} - \begin{bmatrix} -1 \\ 0 \end{bmatrix} \right)^T \begin{bmatrix} x_1 \\ x_2 \end{bmatrix} + \frac{1}{2} (\begin{bmatrix} -1 & 0 \end{bmatrix} \begin{bmatrix} 1 \\ 0 \end{bmatrix} - \begin{bmatrix} 1 & 0 \end{bmatrix} \begin{bmatrix} 1 \\ 0 \end{bmatrix}) \geq -\ln \mu$$

$$h(x) = 2x_1 \begin{matrix} \omega_2 \\ \omega_1 \end{matrix} \geq -\ln \mu$$

Subject:

Year: Month: Date: 23



$$E_2 = \int_{R_1} P_2(x) \cdot dx \cdot E_1$$

μ	4	2	1	$\frac{1}{2}$	$\frac{1}{4}$
	0.09		0.15		
E_2	0.09	0.16	0.38		

Error Table 3.1 براساس

The Minmax Test

• صورت سنڌ

$$c(x) = \frac{P_1(x)}{P_2(x)} \sum_{w_1}^{w_2} \frac{P_2}{P_1}$$

اگر احتمال اوليه (P_1) تغير ٿيندو، تقسيم ٿيڻي جڙوڻي باهه ٿيندي.
 ۽ مثال بهي ۽ با تغير احتمال نوع ماهي در منطقه اي مختلف

$$r = E \{ cost \}$$

$$r = \int_{R_1} \{ c_{11} P_1 P_1(x) + c_{21} P_2 P_2(x) \} dx + \int_{R_2} \{ c_{12} P_2 P_1(x) + c_{22} P_1 P_2(x) \} dx$$

$$r = c_{12} P_1 + c_{22} P_2 + \int_{R_1} \{ -(c_{12} - c_{11}) P_1 P_1(x) + (c_{21} - c_{22}) P_2 P_2(x) \} \cdot dx$$

$$P_1 + P_2 = 1 \rightarrow P_2 = 1 - P_1$$

$$r = c_{22} + (c_{21} - c_{22}) \int_{R_1} P_2(x) dx + P_1 \left[(c_{11} - c_{22}) + (c_{12} - c_{11}) \int_{R_2} P_1(x) dx - (c_{21} - c_{22}) \int_{R_1} P_1(x) dx \right]$$


Subject:

Year:

Month:

Date:

()




$$P_1 = 0$$

$$P_1 = 1 \rightarrow \text{cost} = 0$$

چه تابعی است $\text{cost} - P(w_1)$ این تابع متغیر بین است؟ با اثبات ریاضی

• برای آن که P در cost ، باید cost بیشترین را کم کرد ← min max



$$r = K_1 + P_1 \cdot K_2 \xrightarrow{\text{minimize}} K_2 = 0$$

یعنی P_1 است r است P_1 است

$$(C_{11} - C_{22}) + (C_{12} - C_{11}) \int_{R_2} P_1(x) \cdot dx = (C_{21} - C_{21}) \int_{R_1} P_2(x) \cdot dx$$

• حالات خاص
* هزینه تقسیم گیری هزینه باشد و خطای P_1 باشد

$$C_{11} = C_{22} = 0$$

$$C_{21} = C_{12} \rightarrow \int_{R_2} P_1(x) \cdot dx = \int_{R_1} P_2(x) \cdot dx \rightarrow E_1 = E_2$$

Subject:

Year: Month: Date: 24

Receiver Operating Characteristic (ROC) *

$$E_1 = \int_{R_2} P_1(x) \cdot dx$$

$$E_2 = \int_{R_1} P_2(x) \cdot dx$$

E_i → Error Probability Type (i)

w_1 : Positive Class → False Negative Rate (FNR)

w_2 : Negative Class → False Positive Rate (FPR)


Radar

w_1 : Target → Missed Detection


w_2 : Noise → False Alarm

Detection: $1 - E_1$



درصد کشف است



میانگین تفاوت $d = |m_1 - m_2|$



$d = |m_1 - m_2| = 0$ میانگین بیان





Subject:

Year: Month: Date: ()

$1 - E_1$ (Detection)

ROC منحنی



Subject:

Year: Month: Date: 25

Multi-hypothesis Testing *

M-class problem

$$q_1(x), \dots, q_M(x)$$

$$\underline{x} \in \omega_i \quad q_i(x) > q_j(x)$$

$$q_i(x) = \max_{\forall j} q_j(x) \quad \forall j \neq i$$

c_{ij}

i: true class

j: decision

$$r = \sum_{j=1}^M \sum_{i=1}^M \int_{R_j} c_{ij} P_i(x) dx$$

Single-hypothesis Testing *

مشغلت آماري تهذيب اطلس برصود است.
در بن نظارت تقديري، تشخيص يك دشمن است.

Target Class: t

$$\underline{m}_t, [\Sigma]_t$$

$$d^2(x) = (x - \underline{m}_t)^T [\Sigma]_t^{-1} (x - \underline{m}_t) \quad \text{فاصله مانه لاژيس}$$

اگر x متغير تصادفي باشد، فاصله نیز متغير تصادفي می شود.

$$D^2 = (x - \underline{m}_t)^T [\Sigma]_t^{-1} (x - \underline{m}_t)$$

ايک متبيل whitening

$$\underline{z} = [a]^T (x - \underline{m}_t)$$

Subject:

Year:

Month:

Date:

()

$$\Rightarrow E\{\underline{Z}\} = \underline{0}, \text{cov}\{\underline{Z}\} = [I]$$

$$D^2 = \underline{Z}^T \underline{Z}$$

$$\underline{Z} = \begin{bmatrix} z_1 \\ \vdots \\ z_i \\ \vdots \\ z_n \end{bmatrix} \Rightarrow D^2 = \sum_{i=1}^n z_i^2 \rightarrow z_i \text{ are uncorrelated}$$

$$E\{D^2\} = E\{\underline{Z}^T \underline{Z}\} = E\left\{\sum_{i=1}^n z_i^2\right\} = \sum_{i=1}^n E\{z_i^2\} = n$$

$$\begin{aligned} \text{var}\{D^2\} &= E\{(D^2)^2\} - E^2\{D^2\} \\ &= \sum_i \{z_i^4\} + \sum_{i \neq j} E\{z_i^2 z_j^2\} - E^2\{D^2\} \end{aligned}$$

if z_i & z_j are independent

$$\begin{aligned} \text{var}\{D^2\} &= n E\{z_i^4\} + n(n-1) E\{z_i^2\} E\{z_j^2\} - E^2\{D^2\} \\ &= n E\{z_i^4\} - n E^2\{z_i^2\} = n \gamma \end{aligned}$$

$$\gamma = E\{z_i^4\} - 1$$

همه ی توزیع نرمال z_i .

$$E\{z_i^4\} = 3 E^2\{z_i^2\} = 3 \Rightarrow \gamma = 2$$

همه برای تست نرمال بودن توزیع داده ؟ $\gamma \stackrel{?}{=} 2$

$$E\{D^2 | \omega_t\} = n$$


$$\text{var}\{D^2 | \omega_t\} = n \gamma \quad \text{where } \gamma = E\{z_i^4\} - 1$$

Subject:

Year: _____ Month: _____ Date: 26

$$D^2 = \underline{z}^T \underline{z} = \sum_{i=1}^n z_i^2$$

$n \gg 0$ Central Limit Theorem → توزیع D^2 به سمت توزیع نرمال می‌رود



$$E\{D^2\} = n$$
$$\sigma^2\{D^2\} = n\lambda$$

Performance of a Single Hypothesis Test

$$\underline{m}_1 = \underline{m}_t = 0 \quad [\Sigma]_1 = [\Sigma]_t = [I]$$

$$\underline{m}_2 = \underline{m} = \text{non-target class} \quad [\Sigma]_2 = [\lambda] = \text{diag}\{\lambda_1, \dots, \lambda_n\}$$

برسند با این نظری کردن بهینه‌سازی می‌توان به این شرایط رسید

$$D^2 = (\underline{x} - \underline{m}_t)^T [\Sigma]_t^{-1} (\underline{x} - \underline{m}_t) \rightarrow \text{فاصله از خط مرز}$$
$$= \underline{z}^T \underline{z}$$
$$= \sum_{i=1}^n z_i^2$$

$$E\{D^2 | \omega_t\} = n$$

$$\text{var}\{D^2 | \omega_t\} = n\lambda$$

$$D^2 = \underline{x}^T \underline{x} = (\underline{x} - \underline{m} + \underline{m})^T (\underline{x} - \underline{m} + \underline{m})$$
$$= (\underline{x} - \underline{m})^T (\underline{x} - \underline{m}) + 2 \underline{m}^T (\underline{x} - \underline{m}) + \underline{m}^T \underline{m}$$
$$= \text{tr}[(\underline{x} - \underline{m})^T (\underline{x} - \underline{m})] + 2 \underline{m}^T (\underline{x} - \underline{m}) + \underline{m}^T \underline{m}$$

Subject:

Year:

Month:

Date:

()

$$E\{D^2 | \omega_2\} = \text{tr} \left[E\{(\underline{X}-\underline{m})(\underline{X}-\underline{m})^T | \omega_2\} + 2\underline{m}^T E\{(\underline{X}-\underline{m}) | \omega_2\} + \underline{m}^T \underline{m} \right]$$

$$= \sum_{i=1}^n \lambda_i + \sum_{i=1}^n m_i^2$$

$$\text{var}\{D^2 | \omega_2\} = E\{(D^2)^2 | \omega_2\} - E^2\{D^2 | \omega_2\}$$

$$E\{(D^2)^2 | \omega_2\} = E\{(\underline{X}-\underline{m})^T (\underline{X}-\underline{m})(\underline{X}-\underline{m})^T (\underline{X}-\underline{m}) | \omega_2\}$$

$$+ 4 \underline{m}^T E\{(\underline{X}-\underline{m})^T (\underline{X}-\underline{m}) | \omega_2\} \underline{m}$$

$$+ 2 E\{(\underline{X}-\underline{m})^T (\underline{X}-\underline{m}) | \omega_2\} \underline{m}^T \underline{m}$$

$$+ (\underline{m}^T \underline{m})^2$$

$$= 3 \sum_i \lambda_i^2 + \sum_i \sum_{j \neq i} \lambda_i \lambda_j$$

$$+ 4 \sum_i \lambda_i m_i^2$$

$$+ (\sum_i m_i^2)^2 + 2 (\sum_i \lambda_i) (\sum_i m_i^2)$$

$$\text{var}\{D^2 | \omega_2\} = 2 \sum_{i=1}^n \lambda_i^2 + 4 \sum_{i=1}^n \lambda_i m_i^2$$


عربیت آوده حاصل این ثابت از بعد (E_x) بویب عبد (دع) سیدالباقر است

Subject:

Year: Month: Date: 27

Estimation of Error Rates

$$\begin{aligned} \epsilon &= P_1 \epsilon_1 + P_2 \epsilon_2 \\ &= P_1 \int_{R_2} P_1(x_2) dx_2 + P_2 \int_{R_1} P_2(x_1) dx_1 \end{aligned}$$



$$P_1(x) = x - 2.5 = 0$$

$$\epsilon_B = \frac{1}{8}$$

$$\epsilon_A = 0.125$$

Sample Counting

$$N \text{ Sample} \begin{cases} N_1 \in \omega_1 \\ N_2 \in \omega_2 \\ N_1 + N_2 = N \end{cases}$$


$P(x) \rightarrow$ مدل

Training Sample \rightarrow

Test Sample \rightarrow

• تعداد داده زیاد
 آموختن سیستم و تابع آموختن
 ارزیابی سیستم

تعداد داده کمی خطا را شمارش می کنیم. با
 افزایش آن به دفعات زیاد می شود، میانگین تخمین به مقدار واقعی میل می کند.



Leave-one-out روش $N-1$ ارزیابی کنیم \leftarrow روش

Subject:

Year: Month: Date: ()

Linear Boundaries

*

w_1 & w_2 are Normally Distributed

$$[\Sigma]_1 = [\Sigma]_2 = [\Sigma]$$

$$H \equiv h(x) = \underbrace{(m_2 - m_1)^T [\Sigma]^{-1} x}_{\text{discriminant}} + \frac{1}{2} (m_1^T [\Sigma]^{-1} m_1 - m_2^T [\Sigma]^{-1} m_2) \sum_{w_i} \ln \frac{P_1}{P_2}$$

$$* E \{ H(x) | w_i \} = \eta_i$$

$$\eta_i = E \{ H(x) | w_i \}$$

$$= (m_2 - m_1)^T [\Sigma]^{-1} m_i + \frac{1}{2} \frac{(m_1^T [\Sigma]^{-1} m_1 - m_2^T [\Sigma]^{-1} m_2)}{(m_2 - m_1)^T [\Sigma]^{-1} (m_2 - m_1)} \sum_{w_i} \ln \frac{P_1}{P_2}$$

$$\eta_1 = - \frac{1}{2} (m_2 - m_1)^T [\Sigma]^{-1} (m_2 - m_1) = \underline{-\eta}$$

$$\eta_2 = + \frac{1}{2} (m_2 - m_1)^T [\Sigma]^{-1} (m_2 - m_1) = \underline{+\eta}$$

$$* \text{Var} \{ H(x) | w_i \} = \sigma_i^2 = E \{ (H - \eta_i)^2 | w_i \}$$

$$\sigma_i^2 = E \left\{ \left((m_2 - m_1)^T [\Sigma]^{-1} x - \frac{1}{2} (m_2 - m_1)^T [\Sigma]^{-1} (m_2 - m_1) - \eta_i \right)^2 \right\}$$

$$= E \left\{ \left[(m_2 - m_1)^T [\Sigma]^{-1} (x - m_i) \right]^2 | w_i \right\}$$


$$= (m_2 - m_1)^T [\Sigma]^{-1} E \{ (x - m_i)(x - m_i)^T | w_i \} [\Sigma]^{-1} (m_2 - m_1)$$

$[\Sigma]_i \rightarrow [\Sigma]$

$$= (m_2 - m_1)^T [\Sigma]^{-1} (m_2 - m_1) = \underline{2\eta}$$

Subject: _____

Year: _____ Month: _____ Date: 28



$$E_1 = \int_t^{+\infty} P(h|w_1) dh \Rightarrow E_1 = \int_{t+\eta}^{+\infty} \frac{1}{\sqrt{2\pi}} e^{-\xi/2} d\xi$$

$$E_2 = \int_{-\infty}^t P(h|w_2) dh \Rightarrow E_2 = \int_{-\infty}^{\frac{t+\eta}{\sigma}} \frac{1}{\sqrt{2\pi}} e^{-\xi/2} d\xi$$

$h(x) \rightarrow$ Quadratic function

$[\Sigma]_1, [\Sigma]_2$

$$H(x) = \frac{1}{2} \underbrace{(x - m_1)^T [\Sigma]_1^{-1} (x - m_1)}_A - \frac{1}{2} \underbrace{(x - m_2)^T [\Sigma]_2^{-1} (x - m_2)}_B + \frac{1}{2} \ln \frac{|\Sigma_1|}{|\Sigma_2|} - t \sum_{w_i}^{w_2} \omega_i$$

$$E\{A\} = \text{trace} [\Sigma]_1^{-1} E\{(x - m_1)(x - m_1)^T\}$$

$$E\{B\} = -\frac{1}{2} E\{(x - m_2)^T [\Sigma]_2^{-1} (x - m_2)\}$$

$$= -\frac{1}{2} E\{((x - m_1) - (m_2 - m_1))^T [\Sigma]_2^{-1} ((x - m_1) - (m_2 - m_1))\}$$

$$= -\frac{1}{2} E\left\{ \text{trace} \left\{ [\Sigma]_2^{-1} \left[(x - m_1)(x - m_1)^T - (m_2 - m_1)(x - m_1)^T - (x - m_1)(m_2 - m_1)^T + (m_2 - m_1)(m_2 - m_1)^T \right] \right\} \right\}$$

Subject:

Year: Month: Date: ()

$$= -\frac{1}{2} \text{trac} \left\{ [\Sigma]_2^{-1} [\Sigma]_1 + (m_2 - m_1)(m_2 - m_1)^T \right\}$$

$$\eta_1 = E \{ H(\underline{x}) | \omega_1 \} = A + B = \frac{1}{2} \left\{ \text{trac} \{ [I] - [\Sigma]_2^{-1} [\Sigma]_1 \} \right. \\ \left. - \frac{1}{2} (m_2 - m_1)^T [\Sigma]_2^{-1} (m_2 - m_1) \right.$$

$$\left. + \frac{1}{2} k_n \frac{|\Sigma_1|}{|\Sigma_2|} \right\} - t$$

$$\eta_2 = E \{ H(\underline{x}) | \omega_2 \} = -\eta_1$$

بافتوری کردن بنویسید در ماتریس Σ_2 و Σ_1 داریم:

$$E \{ H(\underline{x}) | \omega_1 \} = \frac{1}{2} \sum_{i=1}^n \left[\left(1 - \frac{1}{\lambda_i} \right) - \frac{(d_{2i} - d_{1i})^2}{\lambda_i} + k_n \frac{1}{\lambda_i} \right] - t$$

$$\text{var} \{ H(\underline{x}) | \omega_1 \} = E \{ (H(\underline{x}) - \eta_1)^2 | \omega_1 \} = \frac{1}{2} \sum_{i=1}^n \left[\left(1 - \frac{1}{\lambda_i} \right) + 2 \frac{(d_{2i} - d_{1i})^2}{\lambda_i^2} \right]$$

در متن برابر است!

$$\text{var} \{ H(\underline{x}) | \omega_1 \} = \frac{1}{2} \text{tr} \left\{ ([I] - [\Sigma]_2^{-1} [\Sigma]_1)^2 + (m_2 - m_1)^T [\Sigma]_2^{-1} [\Sigma]_1 [\Sigma]_2^{-1} (m_2 - m_1) \right\}$$

Upper Bounds on the Bayes Error

*

Charnoff Bound.

$$\text{Bayes Error: } E = \int \min [P_1 p_1(\underline{x}), P_2 p_2(\underline{x})] \cdot d\underline{x}$$

Subject:

Year: _____ Month: _____ Date: 29

$$a, b > 0$$

$$\min[a, b] \leq a^s b^{1-s}, \quad 0 < s < 1$$

اثبت

$$a^s b^{1-s} = a \left(\frac{b}{a}\right)^{1-s}$$

$$1-s > 0$$

$$\left(\frac{b}{a}\right)^{1-s} > a = \min[a, b]$$

فرض $\min[a, b] = a \Rightarrow \left(\frac{b}{a}\right) \geq 1$

Chernoff Bound

$$0 < s < 1$$

$$E_{\omega} = P_1^s \cdot P_2^{(1-s)} \int P_1^s(x) \cdot P_2^{(1-s)}(x) dx$$

حالت خاصي

$$\omega_1 : N(\underline{m}_1, [\Sigma]_1)$$

$$\omega_2 : N(\underline{m}_2, [\Sigma]_2)$$

$$\int P_1^s(x) P_2^{(1-s)}(x) dx = e^{-\mu(s)}$$

ناتج Chernoff

$$\mu(s) = \frac{s(1-s)}{2} (\underline{m}_2 - \underline{m}_1)^T \left[s[\Sigma]_1 + (1-s)[\Sigma]_2 \right]^{-1} (\underline{m}_2 - \underline{m}_1)$$

ناتج باين و ترتيب

$$+ \frac{1}{2} \ln \frac{|s[\Sigma]_1 + (1-s)[\Sigma]_2|}{|[\Sigma]_1|^s |[\Sigma]_2|^{(1-s)}}$$

ناتج برائين و ترتيب

حالت خاصي ناتج Chernoff

$$s = \frac{1}{2} \rightarrow \text{Bhattacharyya Distance}$$

$$\mu\left(\frac{1}{2}\right) = \frac{1}{8} (\underline{m}_2 - \underline{m}_1)^T \left[\frac{1}{2} \Sigma_1 + \frac{1}{2} \Sigma_2 \right]^{-1} (\underline{m}_2 - \underline{m}_1) + \frac{1}{2} \ln \frac{|\frac{1}{2} \Sigma_1 + \frac{1}{2} \Sigma_2|}{\sqrt{|\Sigma_1| |\Sigma_2|}}$$

Subject:


Year. Month. Date. ()

شاخص فاصله Bhattacharyya معیار خوبی برای مقایسه دو توزیع است و میزان نزدیکی و دور بودن آنها را یقین می‌کند.

$$S \Rightarrow \mu(S) \uparrow \Rightarrow \epsilon_u \downarrow$$

1, 2, 3, 4, 6, 8

1, 2, 3, 4 (a ~ c), 5, 6, 7, 10

دفعه سوم  ترتیب کلاس‌بندی
سوال
Hand Out

تاریخ تحویل: ۱۷, ۱۸, ۲۱

* روشهای محاسبه خطا

$$P_i(x) \rightarrow \epsilon = P_1 \epsilon_1 + P_2 \epsilon_2$$

$$P_i(h) \rightarrow \text{mapping } nD \rightarrow 1D$$

Approximation ϵ

Upper bound \rightarrow Chernoff

$$\epsilon = \int_{-\infty}^{+\infty} \min [P_1, P_2] dx \leq P_1^s P_2^{(1-s)} \int_{-\infty}^{+\infty} P_1^s(x) P_2^{(1-s)}(x) dx$$

$$\omega_1: N(m_1, [\Sigma]_1)$$

$$\omega_2: N(m_2, [\Sigma]_2)$$

$$\int P_1^s(x) P_2^{(1-s)}(x) dx = e^{-\mu(s)} \rightarrow \mu(s) = \text{Chernoff distance}$$

Subject:

Year: _____ Month: _____ Date: 30

اثبات:

$$\begin{matrix} [\Sigma]_1 & \longrightarrow & [I] \\ [\Sigma]_2 & \longrightarrow & [\lambda] \end{matrix} \left\{ \begin{array}{l} \text{رقعی سندان} \\ m_1 = \underline{d}_1 \\ m_2 = \underline{d}_2 \end{array} \right.$$

$$\underline{y} = [a]^T x$$

$$\underline{d}_1 = [d_{11} \ d_{12} \ \dots \ d_{1e} \ \dots \ d_{1n}]^T$$

↙ e^{th} element of \underline{d}_1

$$A = \int P_1^{(1-s)}(x) \cdot P_2^{(s)}(x) \cdot dx = \int \frac{\exp\left[-\frac{1}{2}\left\{(1-s)(y-d_1)^T(y-d_1) + s(y-d_2)^T[\lambda]^{-1}(y-d_2)\right\}\right]}{(2\pi)^{n/2} |[I]|^{(1-s)/2} \cdot |[\lambda]|^{s/2}} dy$$

$$A = \prod_{e=1}^n \int_{-\infty}^{+\infty} \frac{1}{\lambda e^{s/2} (2\pi)^{1/2}} \exp\left[-\frac{1}{2}\left\{(1-s)(y_e-d_{1e})^2 + \frac{s}{\lambda e} (y_e-d_{2e})^2\right\}\right] dy_e$$

تبدیل کردن مخرج

$$A = \prod \frac{1}{\lambda e^{s/2} \left\{(1-s) + \frac{s}{\lambda e}\right\}^{1/2}} \times \exp\left\{-\frac{s(1-s)}{2} \frac{(d_{2e}-d_{1e})^2}{s+(1-s)\lambda e}\right\}$$

$$\times \int_{-\infty}^{+\infty} \frac{\left\{(1-s) + \frac{s}{\lambda e}\right\}^2}{(2\pi)^{1/2}} \exp\left[-\frac{\left\{(1-s) + \frac{s}{\lambda e}\right\}}{2} \left\{y_e - d_{1e} - \frac{\frac{s}{\lambda e}(d_{2e}-d_{1e})}{(1-s) + \frac{s}{\lambda e}}\right\}^2\right] dy_e$$

$$\int_{-\infty}^{+\infty} e^{-\alpha x^2} dx = \sqrt{\frac{\pi}{\alpha}} \quad \leftarrow \alpha$$

$$A = \prod \frac{\lambda e^{(1-s)/2}}{\{s+(1-s)\lambda e\}^{1/2}} \exp\left[-\frac{s(1-s)}{2} \frac{(d_{2e}-d_{1e})^2}{s+(1-s)\lambda e}\right]$$

حال معادله بسط داده شده را به حالت ماتریسی برمی گردانیم

$$A = \frac{|[I]|^{s/2} |[\lambda]|^{(1-s)/2}}{|s[I] + (1-s)[\lambda]|^{1/2}} \cdot \exp\left[-\frac{s(1-s)}{2} (d_2 - d_1)^T \{s[I] + (1-s)[\lambda]\}^{-1} (d_2 - d_1)\right]$$


حال از قضیه $y = x$ برمی گردیم و فوژل ثابت می شود.

Subject:

Year:

Month:

Date: ()



• مقدار کمینه s

- * روش عددی
- * روش آنالیزی

Bhattacharyya Bound $\rightarrow s = 1/2$

$$E_{cl} = \sqrt{P_1 P_2} \int_{-\infty}^{+\infty} \sqrt{P_1(x) P_2(x)} dx = \sqrt{P_1 P_2} e^{-\mu(1/2)}$$

$$\mu(1/2) = \frac{1}{8} (m_2 - m_1)^T \left[\frac{\Sigma_1 + \Sigma_2}{2} \right]^{-1} (m_2 - m_1) + \frac{1}{2} \ln \frac{|\Sigma_1 + \Sigma_2|}{\sqrt{|\Sigma_1| |\Sigma_2|}}$$

• نام BHattacharyya : میزان شبیه بودن دو توزیع

* سمت اول : برای اندکی حمل میانگین

* سمت دوم : برای اندکی حمل میانگین

* جای انتخاب ویژگی ؟ از این فاصله استفاده می شود تا ویژگیها از هم دور باشند

پس Feature ای انتخاب می شود تا این فاصله بیشینه شود.

Subject:

Year: _____ Month: _____ Date: 31

✓

$$\omega_1 : N_x(\underline{0}, [1])$$

$$\omega_2 : N_x(\underline{0}, [1])$$

B.D.:

$$\mu\left(\frac{1}{2}\right) = \frac{1}{2} \sum_{i=1}^n \ln \frac{1 + \lambda_i}{2\sqrt{\lambda_i}}$$

$$[\Sigma_x] = \text{diag}\{\lambda_1, \dots, \lambda_n\} \rightarrow \lambda_i > 0 \rightarrow \frac{1 + \lambda_i}{2\sqrt{\lambda_i}} \gg 1$$

$$\lambda_i = 1 : \omega_1 = \omega_2 !!!$$

$$\lambda_i \neq 0 : n \rightarrow +\infty \Rightarrow \mu\left(\frac{1}{2}\right) \rightarrow \infty \Rightarrow \mathcal{E}_u = e^{-\mu\left(\frac{1}{2}\right)} \rightarrow 0$$


n-D

✓

$X_i \rightarrow$ iid = independent & identically distributed

$\omega_1 = P_1(x) \rightarrow$ uniformly distributed [0.4, 0.6]

$\omega_2 = P_2(x) \rightarrow$ uniformly distributed [0, 1]



$$\text{B.D.} : \mathcal{E}_u = \sqrt{P_1 P_2} \int_{-\infty}^{+\infty} \sqrt{P_1(x_1) P_2(x_1)} dx \xrightarrow{\text{iid}} \mathcal{E}_u = \sqrt{P_1 P_2} \prod_{i=1}^n \int \sqrt{P_1(x_i) P_2(x_i)} dx_i$$

$$\mathcal{E}_u = \sqrt{P_1 P_2} \prod_{i=1}^n \int_{0.4}^{0.6} \sqrt{(5)(1)} dx_i = \sqrt{P_1 P_2} \pi (\sqrt{5} (0.2)) = \sqrt{P_1 P_2} (0.447)^n$$

P4PCO

$$n \rightarrow +\infty \Rightarrow \mathcal{E}_u \rightarrow 0$$

✓

Subject:

Year:

Month:

Date:

()

• باافزانه کردن Feature ؟

← افزانه کردن dimensionality

← $E u$

← بهبود کارایی (خطای کم)

• ولیکن پس از این محدود کارایی دیگر بالا نمی رود و شناسایی الگو تنها در عمل صورت می نگیرد و به آن Curse of Dimensionality می گویند.

• انواع دیگری از حد بالا وجود دارد:

$$\min [a, b] \leq a^s b^{(1-s)}$$

chernoff *

$$\min [a, b] \leq \sqrt{ab}$$

bhattacharyya *

$$\min [a, b] \leq \frac{2ab}{(a+b)}$$

asymptotic nearest neighbor *

$$\min [a, b] \leq \frac{2ab}{(a+b)} \leq \sqrt{ab}$$

← تقریب نیک تر از \sqrt{ab} است

Characteristic Function of Random Vector *

$$F(\omega) = E \{ \exp(-j\omega X) \}$$

1-D

$$F(\omega) = \int_{-\infty}^{+\infty} P_X(x) \exp(+j\omega X) dx$$

عملکردی مشابه تبدیل فوری دارد.

Parametric Classifiers

*

• به واسطه تابع توزیع داده از روشهای فصل قبل (استاندارد می شود).
 در این حالت ما به این مسئله می پردازیم که داده های ما چگونه است.

• در این فصل n داده می پردازیم.

$$\underline{x}_i^k \quad i = 1, \dots, N$$

$$k = 1, \dots, M$$

$h(\underline{x})$ → desired parametric form of classifier

□ $h(\underline{x}) \sim$ linear Classifier

$$h(\underline{x}) = \underline{v}^T \underline{x} + v_0 = \underline{w}^T \underline{x}$$


$\left\{ \begin{array}{l} \text{threshold} \rightarrow \text{to be learned} \\ \text{weight vector} \rightarrow n-D \end{array} \right.$

$$h(\underline{x}) = \underline{v}^T \underline{x} = \sum_{w_1}^{w_2} - v_0$$

$$\underline{x} = \begin{bmatrix} 1 \\ x_1 \\ \vdots \\ x_n \end{bmatrix} \quad \underline{w} = \begin{bmatrix} v_0 \\ v_1 \\ \vdots \\ v_n \end{bmatrix} \rightarrow \text{augmented weight vector}$$

□ $h(\underline{x}) \sim$ Non-linear

Goal: define \underline{v}^T and v_0 .



Subject:

Year:

Month:

Date: () () ()

Bayes Classifier

2-class

$$\underline{m}_i, [\Sigma]_i \quad i=1, 2$$

$$\begin{aligned}
 * h(x) &= \frac{1}{2} (\underline{x} - \underline{m}_1)^T [\Sigma]_1^{-1} (\underline{x} - \underline{m}_1) \\
 &\quad - \frac{1}{2} (\underline{x} - \underline{m}_2)^T [\Sigma]_2^{-1} (\underline{x} - \underline{m}_2) \\
 &\quad + \frac{1}{2} \ln \frac{|\Sigma_1|}{|\Sigma_2|}
 \end{aligned}
 \begin{array}{l}
 \omega_1 \\
 \omega_2
 \end{array}
 \begin{array}{l}
 \ln \frac{P_1}{P_2}
 \end{array}$$

* if $\Sigma_1 = \Sigma_2 = \Sigma$

$$h(x) = (\underline{m}_2 - \underline{m}_1)^T \Sigma^{-1} \underline{x} + \frac{1}{2} (\underline{m}_1^T \Sigma^{-1} \underline{m}_1 - \underline{m}_2^T \Sigma^{-1} \underline{m}_2) \begin{array}{l} \omega_1 \\ \omega_2 \end{array} \ln \frac{P_1}{P_2}$$

$$\underline{v}^T = (\underline{m}_2 - \underline{m}_1)^T \Sigma^{-1}$$

$$v_0 = \frac{1}{2} (\underline{m}_1^T \Sigma^{-1} \underline{m}_1 - \underline{m}_2^T \Sigma^{-1} \underline{m}_2) - \ln \frac{P_1}{P_2}$$

* if $\Sigma_1 = \Sigma_2 = [I]$

$$h(x) = (\underline{m}_2 - \underline{m}_1)^T \underline{x} + \frac{1}{2} (\underline{m}_1^T \underline{m}_1 - \underline{m}_2^T \underline{m}_2) \begin{array}{l} \omega_1 \\ \omega_2 \end{array} \ln \frac{P_1}{P_2}$$

$$\underline{v}^T = (\underline{m}_2 - \underline{m}_1)$$

$$v_0 = \frac{1}{2} (\underline{m}_1^T \underline{m}_1 - \underline{m}_2^T \underline{m}_2) - \ln \frac{P_1}{P_2}$$

Correlation

$$x_3[n] = x_1[n] \otimes x_2[n] = \sum_m x_1[m] x_2[m+n]$$

$$x_3[0] = \sum_m x_1[m] x_2[m] = \underline{x}_1^T \underline{x}_2$$

correlation at origin

Correlation Clas. Bayes Clas. $\Sigma_1 = \Sigma_2 = [I]$

Subject:

Year: Month: Date: 33

Optical Pattern Recog. و Correlation Classifier

سرعت پردازش به اندازه سرعت پردازش

*

Bayes Classifier: $\Sigma_1 = \Sigma_2 = [I]$

$$h(x) = (\underline{m}_2 - \underline{m}_1)^T x + \frac{1}{2} (\underline{m}_1^T \underline{m}_1 - \underline{m}_2^T \underline{m}_2) \gtrsim \ln \frac{P_1}{P_2}$$

حل اگر به آن $x^T x$ اضافه کنیم

$$h(x) = \underbrace{(x^T x - 2\underline{m}_1^T x + \underline{m}_1^T \underline{m}_1)}_{\|\underline{x} - \underline{m}_1\|^2} - \underbrace{(x^T x - 2\underline{m}_2^T x + \underline{m}_2^T \underline{m}_2)}_{\|\underline{x} - \underline{m}_2\|^2} \gtrsim 2 \ln \frac{P_1}{P_2}$$


Bayes Classifier $\Sigma_1 = \Sigma_2 = [I] \rightarrow$ Min Distance Classifier

$$\|\underline{x} - \underline{m}_1\|^2 - \|\underline{x} - \underline{m}_2\|^2 \gtrsim 2 \ln \frac{P_1}{P_2}$$

کینه

بهره

* $[\Sigma] = [\Sigma_1] = [\Sigma_2] \neq [I]$




Subject:

Year: Month: Date: ()

Whitening Transform

$$[\Sigma] \longrightarrow [I]$$




$$P(x) \sim \text{JMF}$$

$$h(x) = \underline{v}^T x + v_0 \sim \text{linear}$$

$$\underline{x} = \begin{bmatrix} x_1 \\ \vdots \\ x_n \end{bmatrix}$$

$$\Rightarrow y = \underline{v}^T x_0$$
$$y \gtrsim -v_0$$



direction
o.f \underline{v}
is important

$$h(x) = \underline{v}^T x + v_0$$

$$H(x) = v_1 x_1 + \dots + v_n x_n + v_0$$

طبقه تقیه سمد مرکزی این بردار تصادفی نتیجه نرمال دارد که امکان:

$$\eta_i = E \{ H | w_i \}$$

$$\sigma_i^2 = \text{var} \{ H | w_i \} \quad i=1, 2$$

داشتن معیارهای انتخاب (criterion):

$$h(x) = \underline{v}^T x + v_0$$

$$\eta_i = E \{ H | w_i \} = \underline{v}^T \underline{m}_i + v_0$$

$$\sigma_i^2 = \text{var} \{ H | w_i \} = \underline{v}^T [\Sigma]_i \underline{v}$$

$$f(\eta_1, \eta_2, \sigma_1^2, \sigma_2^2) \sim \text{تابع شاخص}$$

این سندها بردار جهت \underline{v} و نیز اعمال قانون f است که می تواند آجری
حجت باشد. Fisher, min probability of error
این سندها با سندها یکی است:

$$\text{To find } \underline{v} \rightarrow \frac{\partial f}{\partial \underline{v}} = 0, \frac{\partial f}{\partial v_0} = 0$$

طبق chain rule داریم:

$$(I) \frac{\partial f}{\partial \underline{v}} = \frac{\partial f}{\partial \eta_1} \frac{\partial \eta_1}{\partial \underline{v}} + \frac{\partial f}{\partial \eta_2} \frac{\partial \eta_2}{\partial \underline{v}} + \frac{\partial f}{\partial \sigma_1^2} \frac{\partial \sigma_1^2}{\partial \underline{v}} + \frac{\partial f}{\partial \sigma_2^2} \frac{\partial \sigma_2^2}{\partial \underline{v}}$$

$$(II) \frac{\partial f}{\partial v_0} = \frac{\partial f}{\partial \eta_1} \frac{\partial \eta_1}{\partial v_0} + \frac{\partial f}{\partial \eta_2} \frac{\partial \eta_2}{\partial v_0} + \frac{\partial f}{\partial \sigma_1^2} \frac{\partial \sigma_1^2}{\partial v_0} + \frac{\partial f}{\partial \sigma_2^2} \frac{\partial \sigma_2^2}{\partial v_0}$$

درایم:

$$\frac{\partial \eta_i}{\partial \underline{v}} = \underline{m}_i$$

$$\frac{\partial \sigma_i^2}{\partial \underline{v}} = 2 [\Sigma]_i \underline{v}$$

$$\frac{\partial \eta_i}{\partial v_0} = 1$$

$$\frac{\partial \sigma_i^2}{\partial v_0} = 0$$

Subject:

Year:

Month:

Date:

()

بجائزہ کے نام:

$$(I) \frac{\partial f}{\partial \eta_1} m_1 + \frac{\partial f}{\partial \eta_2} m_2 + \frac{\partial f}{\partial \sigma_1^2} (2 \Sigma_1 \nu) + \frac{\partial f}{\partial \sigma_2^2} (2 \Sigma_2 \nu) = 0$$

$$(II) \frac{\partial f}{\partial \eta_1} + \frac{\partial f}{\partial \eta_2} = 0 \Rightarrow \frac{\partial f}{\partial \eta_1} = - \frac{\partial f}{\partial \eta_2}$$

بنا کر جب ہم ν کی قیمت دیتے ہیں:

$$\underline{\nu} = [s [\Sigma]_1 + (1-s) [\Sigma]_2]^{-1} (m_2 - m_1)$$

where: $s = \frac{\frac{\partial f}{\partial \sigma_1^2}}{\frac{\partial f}{\partial \sigma_1^2} + \frac{\partial f}{\partial \sigma_2^2}}$

دستور ν_0 ہمیں اپنی قیمت دیتے ہیں:


$$\nu_0: \frac{\partial f}{\partial \eta_1} + \frac{\partial f}{\partial \eta_2} = 0$$

$$\underbrace{(m_2 - m_1)^T \Sigma^{-1}}_{\underline{\nu}} + \frac{1}{2} (m_1^T \Sigma^{-1} m_2 - m_2^T \Sigma^{-1} m_2) - \ln \frac{C_1 \sigma_1^2}{C_2 \sigma_2^2} = 0$$

$$\Sigma \rightarrow s [\Sigma]_1 + (1-s) [\Sigma]_2$$

Fisher Criterion

$$f = \frac{(\eta_1 - \eta_2)^2}{\sigma_1^2 + \sigma_2^2}$$



جای جدا کردن دو توزیع
 * فاصله میانگین زیاد
 * فاصله نمره از میانگین کم

$$y = v^T x$$

$$\sigma_i \downarrow \Rightarrow F \uparrow$$

$$|\mu_1 - \mu_2| \uparrow \Rightarrow F \uparrow$$

محاسبات:

$$s = \frac{\frac{\partial F}{\partial \sigma_1^2}}{\frac{\partial F}{\partial \sigma_1^2} + \frac{\partial F}{\partial \sigma_2^2}}$$

$$\frac{\partial F}{\partial \sigma_1^2} = \frac{\partial F}{\partial \sigma_2^2} = \frac{-(\mu_1 - \mu_2)^2}{(\sigma_1^2 + \sigma_2^2)^2} = a \Rightarrow s = \frac{a}{a+a} = \frac{1}{2}$$

$$\underline{v} = \left(\frac{1}{2} \Sigma_1 + \frac{1}{2} \Sigma_2 \right)^{-1} (\underline{m}_2 - \underline{m}_1)$$

Fisher Classifier:

$$\left\{ \begin{array}{l} h(x) = v^T x = (\underline{m}_2 - \underline{m}_1)^T \left(\frac{1}{2} \Sigma_1 + \frac{1}{2} \Sigma_2 \right)^{-1} x \\ v_0: \frac{\partial F}{\partial \mu_1} + \frac{\partial F}{\partial \mu_2} = 0 \end{array} \right.$$

$$f = \frac{P_1 \mu_1^2 + P_2 \mu_2^2}{P_1 \sigma_1^2 + P_2 \sigma_2^2}$$

Subject:

Year:

Month:

Date: ()

between-class scatter

within-class scatter

به ندری برای دستیابی از آنها را نشان می دهد، یعنی این نسبت

محاسبات:

$$\frac{\partial f}{\partial \sigma_i^2} = \frac{-P_i (P_1 \eta_1^2 + P_2 \eta_2^2)}{(P_1 \sigma_1^2 + P_2 \sigma_2^2)^2}$$

$$S = \frac{\partial f / \partial \sigma_1^2}{\partial f / \partial \sigma_1^2 + \partial f / \partial \sigma_2^2} = P_1$$

$$\underline{v} = (P_1 [\underline{\Sigma}]_1 + \underbrace{(1 - P_1)}_{P_2} [\underline{\Sigma}]_2)^{-1} (\underline{m}_2 - \underline{m}_1)$$

* اگر N اندازه داشته باشیم می توان برای محاسبه جهت \underline{v} ، مقادیر $[\underline{\Sigma}]$ را تخمین زد:

$$[\underline{\Sigma}]^i = \frac{1}{N_i - 1} \left(\sum_{e=1}^{N_i} (\underline{x}_e^i - \underline{m}_e^i)(\underline{x}_e^i - \underline{m}_e^i)^T \right)$$

$$\frac{\partial f}{\partial \eta_i} = \frac{2P_i \eta_i}{P_1 \sigma_1^2 + P_2 \sigma_2^2}$$

$$\frac{\partial f}{\partial \eta_1} + \frac{\partial f}{\partial \eta_2} = 0$$

$$\Rightarrow \frac{2P_1 \eta_1 + 2P_2 \eta_2}{P_1 \sigma_1^2 + P_2 \sigma_2^2} = 0 \quad \xrightarrow{\eta_i = \underline{v}^T \underline{m}_i + v_0}$$

$$\Rightarrow 2P_1 (\underline{v}^T \underline{m}_1 + v_0) + 2P_2 (\underline{v}^T \underline{m}_2 + v_0) = 0 \Rightarrow$$

$$\underline{v}^T (P_1 \underline{m}_1 + P_2 \underline{m}_2) + (P_1 + P_2) v_0 = 0$$

$$P_1 + P_2 = 1$$

$$\Rightarrow v_0 = -\underline{v}^T (P_1 \underline{m}_1 + P_2 \underline{m}_2)$$

Subject:

Year: Month: Date: 36


Minimum Probability of Error

$$H(x) = \underline{v}^T \underline{X} + v_0$$

$n \gg 30 \rightarrow$ تقیبه مرکزی \rightarrow توزیع نرمال

$$\eta_i = E\{H | \omega_i\} = \underline{v}^T \underline{m}_i + v_0$$

$$\sigma_i^2 = \text{var}\{H | \omega_i\} = \underline{v}^T [\Sigma]^{-1} \underline{v}$$



min prob. of error

$$f = \mathcal{E}$$

$$\mathcal{E} = P_1 \int_{-\frac{\eta_1}{\sigma_1}}^{+\infty} \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{\xi^2}{2}\right) d\xi + P_2 \int_{-\infty}^{-\frac{\eta_2}{\sigma_2}} \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{\xi^2}{2}\right) d\xi$$

$$\frac{d}{dx} \left[\int_{g_1(x)}^{g_2(x)} f(t) dt \right] = f(g_2(x)) \cdot g_2'(x) - f(g_1(x)) \cdot g_1'(x)$$

$$\frac{\partial f}{\partial \sigma_1^2} = \frac{\partial \mathcal{E}}{\partial \sigma_1^2} = 0 = \frac{P_1}{\sqrt{2\pi}} \exp\left(-\frac{(-\eta_1/\sigma_1)^2}{2}\right) \frac{\partial}{\partial \sigma_1^2} \left(-\frac{\eta_1}{\sigma_1}\right)$$

$$= -\frac{P_1}{\sqrt{2\pi}} \exp\left(-\frac{\eta_1^2}{2\sigma_1^2}\right) \cdot \frac{\partial}{\partial \sigma_1^2} \left(-\frac{\eta_1}{\sqrt{\sigma_1^2}}\right)$$

P4PCO

$$+\frac{1}{2} \eta_1 (\sigma_1^2)^{-\frac{3}{2}} \leftarrow \frac{\partial}{\partial \sigma_1^2} (-\eta_1 (\sigma_1^2)^{-\frac{1}{2}})$$

Subject:

Year:

Month:

Date:

()

$$= - \frac{P_1}{2\sqrt{2\pi} \sigma_1} \cdot \exp\left(-\frac{\eta_1^2}{2\sigma_1^2}\right) \cdot \left(\frac{\eta_1}{\sigma_1^2}\right)$$

$$\frac{\partial F}{\partial \sigma_2^2} = \frac{\partial E}{\partial \sigma_2^2} = + \frac{P_2}{2\sqrt{2\pi} \sigma_2} \cdot \exp\left(-\frac{\eta_2^2}{2\sigma_2^2}\right) \cdot \left(\frac{\eta_2}{\sigma_2^2}\right)$$

$$\frac{\partial F}{\partial \eta_1} = \frac{\partial E}{\partial \eta_1} = \frac{P_1}{\sqrt{2\pi} \sigma_1} \exp\left\{-\frac{\eta_1^2}{2\sigma_1^2}\right\}$$

$$\frac{\partial F}{\partial \eta_2} = \frac{\partial E}{\partial \eta_2} = \frac{P_2}{\sqrt{2\pi} \sigma_2} \exp\left\{-\frac{\eta_2^2}{2\sigma_2^2}\right\}$$

$$\frac{\partial F}{\partial \eta_1} + \frac{\partial F}{\partial \eta_2} = 0 \Rightarrow \frac{P_1}{\sqrt{2\pi} \sigma_1} \exp\left(-\frac{\eta_1^2}{2\sigma_1^2}\right) = \frac{P_2}{\sqrt{2\pi} \sigma_2} \exp\left(-\frac{\eta_2^2}{2\sigma_2^2}\right)$$

طین این فرمول، η کینه حسابی است که $E_1 = E_2$

$$S = \frac{\frac{\partial F}{\partial \sigma_1^2}}{\frac{\partial F}{\partial \sigma_1^2} + \frac{\partial F}{\partial \sigma_2^2}} = \frac{\frac{P_1}{\sqrt{2\pi} \sigma_1} \exp\left(-\frac{\eta_1^2}{2\sigma_1^2}\right) \left(\frac{-\eta_1}{\sigma_1^2}\right)}{\frac{P_1}{\sqrt{2\pi} \sigma_1} \exp\left(-\frac{\eta_1^2}{2\sigma_1^2}\right) \left(\frac{-\eta_1}{\sigma_1^2}\right) + \frac{P_2}{\sqrt{2\pi} \sigma_2} \exp\left(-\frac{\eta_2^2}{2\sigma_2^2}\right) \left(\frac{\eta_2}{\sigma_2^2}\right)}$$

$$S = \frac{-\eta_1 / \sigma_1^2}{-\eta_1 / \sigma_1^2 + \eta_2 / \sigma_2^2} = \frac{1}{1 + \frac{\eta_2 / \sigma_2^2}{-\eta_1 / \sigma_1^2}}$$

قابل تأمل

$$S = \frac{-\eta_1 / \sigma_1^2}{-\eta_1 / \sigma_1^2 + \eta_2 / \sigma_2^2} = \frac{1}{1 + \frac{\eta_2 / \sigma_2^2}{-\eta_1 / \sigma_1^2}}$$

$$\eta_i = \underline{v}^T \underline{m}_i + v_0 \begin{matrix} \omega_2 \\ \omega_1 \end{matrix} \Rightarrow \eta_1 < 0, \eta_2 > 0$$

$$S = \frac{1}{1 + \text{positive}} \Rightarrow 0 < S < 1$$

پس ابتدا باید η_1 و η_2 ، σ_1^2 و σ_2^2 و S و بستر آرمان ν_0 داریم:

$$\nu_0 = \frac{S \sigma_1^2 \underline{\nu}^T \underline{m}_2 + (1-S) \sigma_2^2 \underline{\nu}^T \underline{m}_1}{S \sigma_1^2 + (1-S) \sigma_2^2}$$

با توجه به اینکه مقدار S موجود نیست و باید آن را به روش $Iterative$ بستر می‌تواند.

1. choose S

$$\underline{\nu} = (S \Sigma_1 + (1-S) \Sigma_2)^{-1} (\underline{m}_2 - \underline{m}_1)$$

2. using $\underline{\nu}$

$$\sigma_i^2 = \underline{\nu}^T \Sigma_i \underline{\nu}$$

ν_0

$$\eta_i = \frac{\underline{\nu}^T \underline{m}_i}{\sigma_i} + \nu_0$$

3. calculate ϵ

$$\epsilon = P_1 \int_{-\frac{\eta_1}{\sigma_1}}^{+\infty} \frac{1}{\sqrt{2\pi}} e^{-\xi^2/2} d\xi + P_2 \int_{-\infty}^{\frac{\eta_2}{\sigma_2}} \frac{1}{\sqrt{2\pi}} e^{-\xi^2/2} d\xi$$

4. repeat for new S

بهترین S بستر آمده که کمترین خطا را بدهد. جواب اینست:
اگر ارزش شاخص خطا بخوانیم این مثال را بنویسیم:

$$N \text{ sample } \begin{cases} N_1 \in w_1 \\ N_2 \in w_2 \end{cases}$$

Subject:

Year:

Month:

Date:


()

1. compute $\hat{M}_1, \hat{M}_2, \hat{\Sigma}_1, \hat{\Sigma}_2$

2. for a given S ($0 < S < 1$)

$$\underline{v} = (S \hat{\Sigma}_1 + (1-S) \hat{\Sigma}_2)^{-1} (\underline{m}_2 - \underline{m}_1)$$

3. $\underline{v}^T \underline{x} + v_0$ linear $y + v_0 \Rightarrow y_j^{(i)} = \underline{v}^T \underline{x}_j^{(i)}$ $i=1,2$
 $j=1, \dots, N_i$



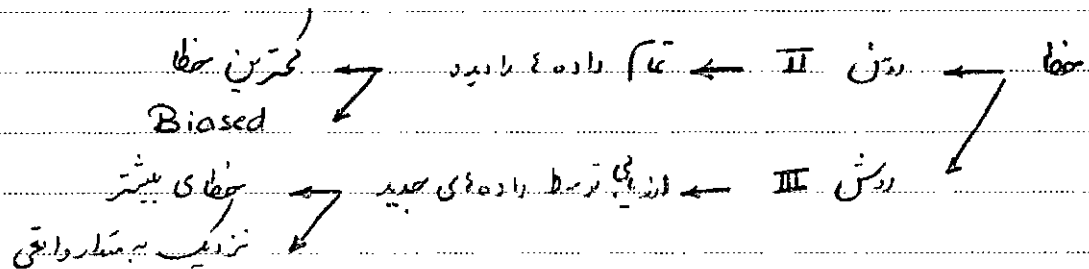
Choose the point where error is smallest

5. change S

این روش از نمونه‌ها بهم در یادگیری و بهم در ارزیابی استفاده می‌کند

در روش سوم، نمونه‌ها را به دو دسته تقسیم می‌کنیم و تعدادی از آنها را برای یادگیری استفاده می‌کنیم و از بقیه برای ارزیابی استفاده می‌کنیم.

Sample Set : $\left\{ \begin{array}{l} \text{Training Set} \\ \text{Test Set} \end{array} \right.$



Subject:

Year: Month: Date: 38

* طراحی کایز دهنده ξ خطی

MSE خطی.


Mean Square Error

$h(x)$ \longrightarrow خطی

$$h(x) = \underline{v}^T x + v_0$$

$\gamma(x)$ \longrightarrow desired form of our classifier

$$\gamma(x) = \begin{cases} -1 & , x \in \omega_1 \\ +1 & , x \in \omega_2 \end{cases}$$



$$\bar{E}^2 = E \{ (H(x) - \gamma(x))^2 \}$$

$$= E \{ H^2(x) - 2\gamma(x) \cdot H(x) + \gamma^2(x) \}$$

$$= \underbrace{E \{ H^2(x) \}}_{II} - 2 \underbrace{E \{ \gamma(x) H(x) \}}_I + \underbrace{\gamma^2(x)}_{\text{deterministic}}$$

Subject:

Year: Month: Date: ()

$$\gamma(\underline{x}) = \begin{cases} -1 & , \underline{x} \in \omega_1 \\ +1 & , \underline{x} \in \omega_2 \end{cases}$$

$$\begin{aligned} \text{I) } E\{H(\underline{x})\gamma(\underline{x})\} &= P_1 E\{H(\underline{x})(-1) | \omega_1\} + P_2 E\{H(\underline{x})(+1) | \omega_2\} \\ &= -P_1 \eta_1 + P_2 \eta_2 \end{aligned}$$

$$E\{X\} = m$$

$$E\{(X-m)^2\} = \text{var}\{X\}$$

$$E\{X^2\} = \sigma_x^2 + \eta_x^2$$

$$\text{II) } E\{H^2(\underline{x})\} = P_1(\sigma_1^2 + \eta_1^2) + P_2(\sigma_2^2 + \eta_2^2)$$

$$\bar{E}^2 = (P_1(\sigma_1^2 + \eta_1^2) + P_2(\sigma_2^2 + \eta_2^2)) - 2(-P_1\eta_1 + P_2\eta_2)$$

$$\underline{V} = (s\Sigma_1 + (1-s)\Sigma_2)^{-1} (m_2 - m_1)$$

$$s = \frac{\frac{\partial f}{\partial \sigma_1^2}}{\frac{\partial f}{\partial \sigma_1^2} + \frac{\partial f}{\partial \sigma_2^2}} \rightarrow s = \frac{P_1}{P_1 + P_2} = P_1$$

$$\frac{\partial f}{\partial \sigma_1^2} = P_1$$

$$s_0 : \frac{\partial f}{\partial \eta_1} + \frac{\partial f}{\partial \eta_2} = 0 \rightarrow \dots$$

Subject:

Year. Month. Date. 39

$$\gamma(x) = q_2(x) - q_1(x)$$

post-priori probability

$$\begin{aligned} I) E\{H(x) \gamma(x)\} &= \int_{-\infty}^{+\infty} h(x) \times \frac{P_2 P_2(x) - P_1 P_1(x)}{P(x)} \cdot P(x) dx \\ &= P_2 \eta_2 - P_1 \eta_1 \end{aligned}$$

میانگین تلیت

Subject:

Year: _____ Month: _____ Date: _____ ()

Subject:

Year: Month: Date: 40

• اگر $[u][u]^T$ را به $[I]$ تبدیل کرد، کارهای آن می شود برای آن
 برابر می آید و به هم می رسد و این کار باید تبدیل کن است.

$$\left. \begin{aligned} \frac{1}{N} \sum_{i=0}^N y_i &= 0 \\ \frac{1}{N} \sum_{i=0}^N y_i y_i^T &= [I] \end{aligned} \right\} \leftarrow y_j \cdot [a]^T x_j + b$$

$$\left. \begin{aligned} y_j &= [a]^T x_j + b \\ d_i &= [a]^T m_i + b \\ [k]_i &= [a][\Sigma]_i [a]^T \end{aligned} \right\} \Rightarrow [u][u]^T = N[I] \Rightarrow \underline{w} = \frac{1}{N} [u'] \Gamma'$$

$$\underline{w} = \frac{1}{N} [u'] \Gamma'$$

$$[u'] = [y_1, \dots, y_N] = [z'_1, \dots, z'_N]$$

$$\underline{w} = \begin{bmatrix} w_0 \\ \underline{w} \end{bmatrix}$$

$$w_0 = \frac{1}{N} \left[\sum_{j=1}^{N_2} \lambda(z'_j) - \sum_{j=N_2+1}^N \lambda(z'_j) \right]$$

$$[w'_1 \dots w'_n]^T = \frac{1}{N} \left[\sum_{j=1}^{N_2} \lambda(y_j) y_j - \sum_{j=N_2+1}^N \lambda(y_j) y_j \right]$$

• می خواهیم این رابطه برقرار باشد:

$$h(z) = \underline{w}^T z \gg 0$$

پس فرض می کنیم که:

$$\lambda(z) = 1$$

Subject:

Year:

Month:

Date:

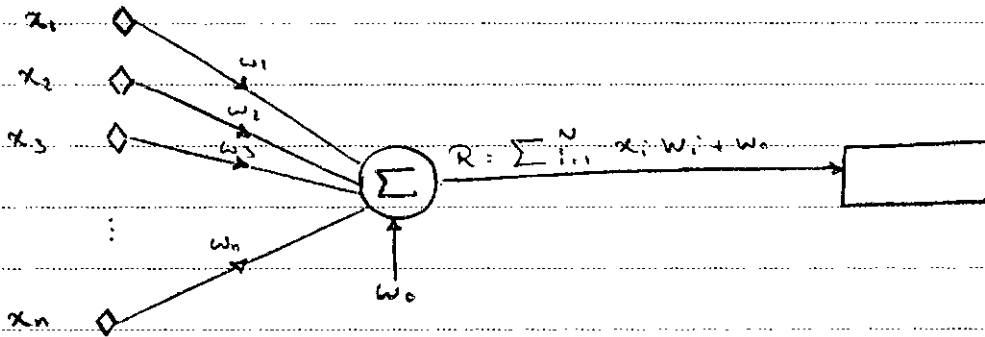
()

ماجره دادن در رابطه ای قبل داریم:

$$W_0 = \frac{N_2}{N} - \frac{N_1}{N} = P_2 - P_1$$

$$\underline{w} = P_2 \underline{d}_2 - P_1 \underline{d}_1$$

گاهی اوقات ما میسیم \underline{w} را به صورت Iterative پیدا کنیم. این روش بسیار نزدیک به Perceptron Approach می باشد.



این از روشهای وزن دهی است Reward - Punishment کردن است.

N_1 sample $\in x_1$

N_2 sample $\in x_2$

$$N_1 + N_2 = N$$

$$h(\underline{x}) = \underline{w}^T \underline{x} + w_0 \begin{matrix} w_1 \\ \vdots \\ w_2 \end{matrix} \gg 0$$

$\underline{w}(1)$ to be initial vector

K^{th} step:

1) $\underline{x}(k) \in \omega_1$ & $\underline{x}^T(k) \underline{w}(k) < 0$

replace $\underline{w}(k)$ by $\underline{w}(k+1) = \underline{w}(k) + c \underline{x}(k)$

$c \equiv$ correction increment ↷

Subject:

Year: Month: Date: 4/1


$$II) \quad \underline{x}(k) \in \omega_2 \quad \& \quad \underline{x}^T(w) \underline{w}(k) \geq 0$$

$$\underline{w}(k+1) = \underline{w}(k) - c \cdot \underline{x}(k)$$

III Other wise

$$\underline{w}(k+1) = \underline{w}(k)$$

ثابت شده است که اگر دو گلاس به صورت خطی جداپذیر باشند، این الگوریتم در مقدار \underline{w} همگراست.



$$\begin{bmatrix} x_1 \\ x_2 \end{bmatrix}, \begin{bmatrix} 0 \\ 0 \end{bmatrix}, \begin{bmatrix} 0 \\ 1 \end{bmatrix} \in \omega_1$$

$$(1,1) \in \omega_1$$

$$(0,0) \in \omega_2$$

$$\begin{bmatrix} 1 \\ 0 \end{bmatrix}, \begin{bmatrix} 1 \\ 1 \end{bmatrix} \in \omega_2$$

$$h(\underline{x}) = \underline{w}^T \underline{x} = \underline{v}^T \underline{x} + v_0$$

$$\omega_1 = \left\{ (0, 0, 1)^T, (0, 1, 1)^T \right\}$$

$$\omega_2 = \left\{ (1, 0, 1)^T, (1, 1, 1)^T \right\}$$

$$\underline{w}(1) = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix} \quad c = 1$$

$$+ \quad \underline{x}(1) \in \omega_1 \quad : \quad \underline{x}(1) = \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix} \quad \left| \Rightarrow \underline{w}(2) = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix} + 1 \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix} = \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix} \right.$$

$$\underline{w}^T(1) \underline{x}(1) = 0$$

$$+ \quad \underline{x}(2) \in \omega_1 \quad : \quad \underline{x}(2) = \begin{bmatrix} 0 \\ 1 \\ 1 \end{bmatrix} \quad \left| \Rightarrow \underline{w}(3) = \underline{w}(2) = \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix} \right.$$

$$\underline{w}^T(2) \underline{x}(2) = 1$$

Subject:

Year: Month: Date: ()

$$\begin{aligned} * \underline{x}(3) \in \omega_2 & \quad \underline{x}(3) = \begin{bmatrix} 1 \\ 0 \\ 1 \end{bmatrix} \quad \Rightarrow \quad \underline{w}(4) = \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix} - 1 \begin{bmatrix} 1 \\ 0 \\ 1 \end{bmatrix} = \begin{bmatrix} -1 \\ 0 \\ 0 \end{bmatrix} \\ & \quad \underline{w}(3)^T \underline{x}(3) = 1 \end{aligned}$$

$$\begin{aligned} * \underline{x}(4) \in \omega_2 & \quad \underline{x}(4) = \begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix} \quad \Rightarrow \quad \underline{w}(5) = \underline{w}(4) \\ & \quad \underline{w}(4)^T \underline{x}(4) = -1 \end{aligned}$$

$$\begin{aligned} * \underline{x}(5) \in \omega_1 & \quad \underline{x}(5) = \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix} \quad \Rightarrow \quad \underline{w}(6) = \begin{bmatrix} -1 \\ 0 \\ 0 \end{bmatrix} + 1 \begin{bmatrix} 0 \\ 0 \\ 1 \end{bmatrix} = \begin{bmatrix} -1 \\ 0 \\ 1 \end{bmatrix} \\ & \quad \underline{w}(5)^T \underline{x}(5) = 0 \end{aligned}$$

$$\begin{aligned} * \underline{x}(6) \in \omega_1 & \quad \underline{x}(6) = \begin{bmatrix} 0 \\ 1 \\ 1 \end{bmatrix} \quad \Rightarrow \quad \underline{w}(7) = \underline{w}(6) \\ & \quad \underline{w}(6)^T \underline{x}(6) = 1 \end{aligned}$$

* ...

$$\underline{w}(12) = \begin{bmatrix} -2 \\ 0 \\ 1 \end{bmatrix}$$

$$\underline{x} \in \omega_2 : \quad (0 \ 0 \ 1) \underline{w}(12) = 1 > 0 \quad \checkmark$$

$$(0 \ 1 \ 1) \underline{w}(12) = 1 > 0 \quad \checkmark$$

$$\underline{x} \in \omega_1 : \quad (1 \ 0 \ 1) \underline{w}(12) = -1 < 0 \quad \checkmark$$

$$(1 \ 1 \ 1) \underline{w}(12) = -1 < 0 \quad \checkmark$$

$$* \underline{w} = \underline{w}(12) = [-2 \ 0 \ 1]^T$$

$$h(\underline{x}) = \underline{x}^T \underline{w} = (x_1 \ x_2 \ 1) \begin{pmatrix} -2 \\ 0 \\ 1 \end{pmatrix} = -2x_1 + 1$$

$$h(\underline{x}) = 0 \rightarrow x_1 = \frac{1}{2}$$

Subject:

Year: _____ Month: _____ Date: 4/2

حل ابرین قانون را در دایره های درجیم.

$$h(x) = v^T x + v_0 \begin{matrix} \omega_1 \\ \omega_2 \end{matrix} > 0$$

$$= \underline{w}^T x > 0$$

if $x \in \omega_2$ then $x = \begin{bmatrix} -x_1 \\ \vdots \end{bmatrix}$

$$\underline{w}(k+1) = \begin{cases} \underline{w}(k) & , \underline{x}^T(k) \underline{w}(k) > 0 \\ \underline{w}(k) + c \underline{x}(k) & , \underline{x}^T(k) \underline{w}(k) \leq 0 \end{cases}$$

نقشه یادگیری پرسپترون

* Fixed Increment Alg.

$c \equiv \text{constant}$

* Absolute Correction Alg.

می خواهیم بهاره c با طریقی تنظیم کنیم تا شرط خاصی را ارضا کند

k^{th} step

$$\underline{w}^T(k) \underline{x}(k) \leq 0$$

$$\underline{w}^T(k+1) \underline{x}(k) = (\underline{w}(k) + c \underline{x}(k))^T \underline{x}(k) > 0$$

$$\Rightarrow c(k) > \frac{|\underline{w}^T(k) \cdot \underline{x}(k)|}{\underline{x}^T(k) \cdot \underline{x}(k)}$$

* Fractional Correction Alg.

$$|\underline{w}^T(k) \cdot \underline{x}(k) - \underline{w}^T(k+1) \cdot \underline{x}(k)| = \lambda |\underline{w}^T(k) \cdot \underline{x}(k)|$$

$$\Rightarrow c = \lambda \frac{|\underline{w}^T(k) \cdot \underline{x}(k)|}{\underline{x}^T(k) \cdot \underline{x}(k)}$$

Subject:

Year: Month: Date: ()

• نسبت شده است که اگر داده x به طور خطی جداپذیر باشند، الگوریتم Perceptron عملی می شود.

• اگر الگوریتم مدتی طولانی متوقف شود، با جواب به سختی به است آمده است یا داده x به طور خطی جداپذیر نیست.

• برای داشتن نتایج مناسب راههای مختلفی وجود دارد:

- * میانگین w را به دست آوریم تا همیشه جواب تقریباً مناسب موجود باشد.
- * غیر خطی بودن به خوبی سمپل داده شود.
- * برجایی که الگوریتم قطع شود، جواب بهترین آن لحظه داده شود.

Packet Algorithm

Packet Algorithm

$w_s \equiv$ Sorted Weight Vector (Packet)

$h_s \equiv$ History Counter

الگوریتم

1. initialize $w(0)$, $h_s = 0$

2. @ the k th Step

— compute & update the weight vector $w(k+1)$
(based on the perceptron rule)

— use $w(k+1)$ to test # of training samples
classified correctly are counted = h

— if $h > h_s$ then

$$w_s = w(k+1)$$

$$h_s = h$$

— continue the iteration

Gradient گاهی اوقات تغییرات برابرسان شیبها میباشند یعنی می تواند برابران می باشد.

The Gradient Technique *

$$\nabla_{\underline{y}} f(\underline{y}) = \text{grad} [f(\underline{y})] = \begin{bmatrix} \frac{df}{dy_1} \\ \frac{df}{dy_2} \\ \dots \\ \frac{df}{dy_n} \end{bmatrix}$$

Positive Gradient \leftarrow جهت طی بردار به سمت بیشترین نرخ تغییرات خواهد بود.

Negative Grad \leftarrow برای اعمال در PR می توان یک criterion بدترین بردار استفاده نمود تغییرات به سمت کمترین کردن همین بردار و به آن روشهای Gradient Descend می گویند.

$$h(\underline{x}) = \underline{w}^T \underline{x} \quad \begin{matrix} \geq w_1 \\ \geq w_2 \end{matrix} \quad \text{①}$$


$$= \underline{w}^T \underline{x} > 0$$

criteria function

$$J(\underline{w}, \underline{x}) = (|\underline{w}^T \underline{x}| - \underline{w}^T \underline{x})$$

solution در حالی است که مدار این تابع کمترین شود. برای بدایران جواب باید تغییرات در

راستی کمینه کردن J پیش رود.



Subject:

Year:

Month:

Date:

()

$$\underline{W}(k+1) = \underline{W}(k) + C(k) \cdot \underline{x}(k)$$


$$\underline{W}(k+1) = \underline{W}(k) - C \nabla_{\underline{w}} J(\underline{W}, \underline{x})$$

Perceptron ψ

$$J(\underline{W}, \underline{x}) = \frac{1}{2} (|\underline{W}\underline{x}| - \underline{W}\underline{x})$$

$$\underline{W}(k+1) = \begin{cases} \underline{W}(k) & , \underline{x}^T(k) \underline{W}(k) > 0 \\ \underline{W}(k) + C \underline{x}(k) & , \underline{x}^T(k) \underline{W}(k) < 0 \end{cases}$$

$$\frac{\partial J(\underline{W}, \underline{x})}{\partial \underline{W}} = \frac{1}{2} (\underline{x} \cdot \text{sgn}(\underline{W}^T \underline{x}) - \underline{x})$$



$$\underline{W}(k+1) = \underline{W}(k) + \frac{C}{2} \{ \underline{x}(k) - \underline{x}(k) \cdot \text{sgn}(\underline{W}^T(k) \cdot \underline{x}(k)) \}$$

$$= \underline{W}(k) + C \cdot \begin{cases} 0 & , \underline{W}^T(k) \cdot \underline{x}(k) > 0 \\ \underline{x}(k) & , \underline{W}^T(k) \cdot \underline{x}(k) < 0 \end{cases}$$

is ψ Reward-Punishment is ψ

criteria function 2

$$J(\underline{W}, \underline{x}) = \frac{1}{4 \underline{x}^T \underline{x}} (|\underline{W}^T \underline{x}|^2 - |\underline{W}^T \underline{x}| \underline{W}^T \underline{x})$$

$$\frac{\partial J(\underline{w})}{\partial \underline{w}} = \frac{1}{4 \underline{x}^T \underline{x}} \left[2 |\underline{w}^T \underline{x}| \underline{x} \cdot \text{sgn}(\underline{w}^T \underline{x}) - |\underline{w}^T \underline{x}| \underline{x} - (\underline{w}^T \underline{x}) \underline{x} \text{sgn}(\underline{w}^T \underline{x}) \right]$$

$$= \frac{1}{2 \underline{x}^T \underline{x}} \left[|\underline{w}^T \underline{x}| \underline{x} \text{sgn}(\underline{w}^T \underline{x}) - |\underline{w}^T \underline{x}| \underline{x} \right]$$

تقریباً معادل Absolute Correction Alg. می باشد.

MSE \downarrow \circ

$$h(\underline{x}) = \underline{v}^T \underline{x} + v_0 \quad \sum_{i=1}^{w_i} \circ$$

$$= \underline{w}^T \underline{x} > 0$$

$$= \sum_{i=0}^n w_i x_i > 0$$

$$\bar{\epsilon}^2 = E \{ (h(\underline{x}) - \delta(\eta))^2 \}$$

sample δ ی مرزی صیقلی میگرداند.
روی MSE تأثیر مثبتی باید داشته باشد، درحالی که در سایر روشها sample δ ی مرزی اهمیت بیشتری دارد می شود.
این روش سعی در اصلاح این وضع دارد:

$$\bar{\epsilon}^2 = \frac{1}{N} \sum_{j=1}^N \left\{ \underline{w}^T \underline{x}_j - |\underline{w}^T \underline{x}_j| \right\}^2$$

$$\underline{w}^T \underline{x}_j \begin{cases} > 0 \\ < 0 \end{cases} \rightarrow \begin{cases} \text{دسته بندی درست} \\ \text{دسته بندی خطا} \end{cases}$$

$\bar{\epsilon}^2 \sim \text{cte}$, $\bar{\epsilon}^2 \uparrow$

$$\bar{\epsilon}^2 = \frac{1}{N} \sum_{j=1}^N \left\{ \text{sgn}(\underline{w}^T \underline{x}_j) - 1 \right\}^2$$

شمارش تعداد خطا

Subject:

Year:

Month:

Date:

()

$$\bar{\epsilon}^2 = E \{ (\hat{h}(x) - y(x))^2 \}$$

$$= \frac{1}{N} \sum_{j=1}^N \{ \underline{w}^T \underline{x}_j - y(\underline{x}_j) \}^2$$

$$= \frac{1}{N} ([\underline{u}]^T \underline{w} - \underline{I}) ([\underline{u}]^T \underline{w} - \underline{I})$$

$$[\underline{u}] = [\underline{x}_1 \dots \underline{x}_N]$$

$$\underline{I} = [y(\underline{x}_1) \dots y(\underline{x}_N)]^T$$

$$\frac{\partial \bar{\epsilon}^2}{\partial \underline{w}} = \frac{2}{N} [\underline{u}] ([\underline{u}]^T \underline{w} - \underline{I})$$

$$\underline{w}(k+1) = \underline{w}(k) - \epsilon \nabla_{\underline{w}} J(\underline{w}, \underline{x})$$

$$\underline{w}(k+1) = \underline{w}(k) - \frac{2\epsilon}{N} \{ [\underline{u}]^T \underline{w}(k) - |[\underline{u}]^T \underline{w}(k)| \}$$

• حال اگر بخواهیم این criterion داشته باشیم که بتوان از آن مشتق بگیریم از روش جدید استفاده می کنیم.

Newton Method

$$\underline{w}(k+1) = \underline{w}(k) - [H]^{-1} \nabla_{\underline{w}} J(\underline{w})$$

$$[H] \equiv \text{Hessian Matrix} \sim \frac{\partial^2 J(\underline{w})}{\partial \omega_i \partial \omega_j}$$

Subject:

Year: Month: Date:

45

Ho - Kashyap

* الديرتم

Sample: $\underline{x}_1, \dots, \underline{x}_N$

$\underline{x}_i \in \omega_1 \quad i = 1, \dots, N_1$

$\underline{x}_i \in \omega_2 \quad i = N_1 + 1, \dots, N$

$$h(\underline{x}) = \underline{v}^T \underline{x} + v_0$$

$$\begin{matrix} \omega_1 \\ \omega_2 \end{matrix} \ominus$$

$$= \underline{w}^T \underline{x} > 0$$



می خواهیم این شرط را بر $b = b_i$ داشته باشیم

$$\begin{cases} h(\underline{x}) = \underline{w}^T \underline{x} = b \\ \underline{w}^T \underline{x}_i = b_i > 0 \end{cases}$$

علم

$$[u] = [x] = [\underline{x}_1 \quad \underline{x}_2 \quad \dots \quad \underline{x}_N]$$

$$[x]^T \underline{w} = \underline{b}$$

$$\underline{b} = \begin{bmatrix} b_1 \\ \vdots \\ b_N \end{bmatrix} > 0$$

$$J(\underline{w}, \underline{x}, \underline{b}) = \frac{1}{2} \sum_{j=1}^N (\underline{w}^T \underline{x}_j - b_j)^2$$

$$= \frac{1}{2} \| [x]^T \underline{w} - \underline{b} \|^2$$

$$\underline{w}^{(k+1)} = \underline{w}^{(k)} - \epsilon \left. \frac{\partial J(\underline{w})}{\partial \underline{w}} \right|_{\underline{w} = \underline{w}^{(k)}}$$

$$\frac{\partial J}{\partial \underline{w}} = [x] ([x]^T \underline{w} - \underline{b})$$

Subject :

Year :

Month :

Date :

$$\frac{\partial J}{\partial \underline{b}} = - ([x]^T \underline{w} - \underline{b})$$

$$\frac{\partial J}{\partial \underline{w}} = \underline{0} \Rightarrow \underline{w} = ([x][x]^T)^{-1} [x] \underline{b} = [x]^{\#} \underline{b}$$

• کجینہ سارے

$$[x]^{\#} = ([x][x]^T)^{-1} [x] \rightarrow \text{generalized inverse of } [x]$$

$$\underline{b} > 0$$

$$\underline{b}(k+1) = \underline{b}(k) - \nabla_{\underline{b}} J(\sim)$$

$$\delta b_i(k) = \begin{cases} 0 & , [x]^T \underline{w} - \underline{b}(k) \leq 0 \\ 2c [x]^T \underline{w}(k) - \underline{b}(k) & , > 0 \end{cases}$$

$$c = c \alpha > 0$$

$$\delta(\underline{b}) = c \left([x]^T \underline{w}(k) - \underline{b}(k) + | [x]^T \underline{w}(k) - \underline{b}(k) | \right)$$

• solution \underline{b} ہے (یا) \underline{b} نہیں ہے

$$\delta(\underline{b}) = c (\underline{e}(k) - |\underline{e}(k)|)$$

$$\underline{w} = [x]^{\#} \underline{b}$$

$$\underline{w}(k+1) = [x]^{\#} \underline{b}(k+1)$$

$$= [x]^{\#} (\underline{b}(k) + c \nabla_{\underline{b}} J(\sim))$$

$$= [x]^{\#} \underline{b} + c [x]^{\#} \nabla_{\underline{b}} J(\sim)$$

$$= \underline{w}(k) + c [x]^{\#} \nabla_{\underline{b}} J(\sim)$$

He - Kashgari Algorithm •

1. initialization

$$\underline{b}(1) > \underline{0}$$

$$\underline{w}(1) = [\underline{x}]^\# \underline{b}(1)$$

2. K^{th} step

$$\underline{e}(k) = [\underline{x}]^T \underline{w}(k) - \underline{b}(k)$$

$$\underline{w}(k+1) = \underline{w}(k) + c [\underline{x}]^\# (\underline{e}(k) + |\underline{e}(k)|)$$


$$\underline{b}(k+1) = \underline{b}(k) + c (\underline{e}(k) + |\underline{e}(k)|)$$

اگر سگ خطی جدا پذیر باشد ← \underline{w} همگرا می شود
 اگر سگ خطی جدا پذیر نباشد ← اگر طبقه عناصر بر خط در طی تکرار مثبت باقی
 نماند نشان می دهد که سگ غیر خطی جدا پذیر است.

2-class

$$\omega_1 = \left\{ \begin{pmatrix} 0 \\ 0 \end{pmatrix}, \begin{pmatrix} 0 \\ 1 \end{pmatrix} \right\}$$

$$\omega_2 = \left\{ \begin{pmatrix} 1 \\ 0 \end{pmatrix}, \begin{pmatrix} 1 \\ 1 \end{pmatrix} \right\}$$



$$\underline{w} = \begin{pmatrix} w_0 \\ w_1 \\ w_2 \end{pmatrix} ; \begin{pmatrix} w_0 \\ w_1 \\ w_2 \end{pmatrix}$$

$$\underline{x} = \begin{pmatrix} 1 \\ x_1 \\ x_2 \end{pmatrix} ; \begin{pmatrix} x_1 \\ x_2 \end{pmatrix}$$

$$[\underline{x}] = \begin{bmatrix} 0 & 0 & -1 & -1 \\ 0 & 1 & 0 & -1 \\ 1 & 1 & -1 & -1 \end{bmatrix}_{3 \times 4} \Rightarrow [\underline{x}]^\# = \left(\begin{bmatrix} [\underline{x}] & [\underline{x}] \end{bmatrix} \begin{matrix} T^{-1} \\ \\ \end{matrix} \right) [\underline{x}] = \frac{1}{2} \begin{bmatrix} -1 & -1 & -1 & -1 \\ -1 & 1 & 1 & -1 \\ \frac{3}{2} & \frac{1}{2} & -\frac{1}{2} & \frac{1}{2} \end{bmatrix}_{3 \times 4}$$

$$\underline{b}(1) > \underline{0}$$

$$\underline{b}(1) = \begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix} \quad c=1$$

Subject:

Year:

Month:

Date:

$$\underline{w}(1) = [\underline{x}]^{\#} \underline{b}(1) = \begin{bmatrix} -2 \\ 0 \\ 1 \end{bmatrix}$$

$$[\underline{x}]^T \underline{w}(1) = \begin{bmatrix} 1 \\ 1 \\ 1 \end{bmatrix}$$


$$\underline{e}(1) = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix} \Rightarrow \underline{w}(1) \equiv \text{solution} \Rightarrow h(\underline{x}) = -2x_1 + 1$$

XOR ✓

$$\omega_1 = \left\{ \begin{bmatrix} 0 \\ 0 \end{bmatrix}, \begin{bmatrix} 1 \\ 1 \end{bmatrix} \right\}$$

$$\omega_2 = \left\{ \begin{bmatrix} 1 \\ 0 \end{bmatrix}, \begin{bmatrix} 0 \\ 1 \end{bmatrix} \right\}$$

$$\underline{b}(1) = \begin{bmatrix} 1 \\ 1 \\ 1 \\ 1 \end{bmatrix}$$



$$[\underline{x}] = \begin{bmatrix} 0 & 1 & 0 & -1 & 1 \\ 0 & 1 & -1 & 0 & 1 \\ 1 & 1 & -1 & -1 & 1 \end{bmatrix} \Rightarrow [\underline{x}]^{\#} = \frac{1}{2} \begin{bmatrix} -1 & 1 & 1 & -1 \\ -1 & 1 & -1 & 1 \\ \frac{3}{2} & -\frac{1}{2} & -\frac{1}{2} & -\frac{1}{2} \end{bmatrix}$$

$$\underline{w}(1) = [\underline{x}]^{\#} \underline{b}(1) = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix}$$

$$\underline{e}(1) = [\underline{x}]^T \underline{w}(1) - \underline{b}(1) = \begin{bmatrix} -1 \\ -1 \\ -1 \\ -1 \end{bmatrix}$$

چون تمام مولدهای $\underline{e}(1)$ منفی است ← مسئله خطی پیدا پذیر نیست.

باشندش نمونه‌های که به خط طبقه بندی شده‌اند:

$$\underline{w}^T \underline{x} = b, \quad b > 0$$

$$J = \frac{1}{2} \sum_{\underline{x} \in Y} \frac{(\underline{w}^T \underline{x} - b)^2}{\|\underline{x}\|^2}$$

Y is set of samples for which $\underline{w}^T \underline{x} < b$

$$\frac{\partial J}{\partial \underline{w}} \equiv \nabla_{\underline{w}} J = \sum_{\underline{x} \in Y} \frac{\underline{w}^T \underline{x} - b}{\|\underline{x}\|^2} \underline{x}$$


updating rule:

$$\underline{w}(k+1) = \underline{w}(k) - c \nabla_{\underline{w}} J$$

$$\underline{w}(k+1) = \underline{w}(k) - c \sum_{\underline{x} \in Y} \frac{b - \underline{w}^T \underline{x}}{\|\underline{x}\|^2} \underline{x}$$

اگر بخواهیم لایه‌های داده‌ها استفاده کرد:

$$\underline{w}(k+1) = \underline{w}(k) - c \times \underbrace{\frac{b - \underline{w}^T(k) \cdot \underline{x}(k)}{\|\underline{x}(k)\|^2}}_r \cdot \underline{x}(k)$$



228 10

Duda & Heart

تغییر w با هر sample درش
 Single-Sample Relaxation with Margin
 می‌توانید و به کل فرکانس با همند نمونه، درش
 Batch Relaxation with Margin
 اطلاق می‌شود.

Subject:

Year:

Month:

Date:

* تعميم در مسائل سمپدا

M-class Problem

$$d_i(\underline{x}) = \underline{w}_i^T \underline{x} \quad i^{\text{th}} \text{ class}$$

$$\underline{x} \in \omega_i$$

$$d_i(\underline{x}) > d_j(\underline{x}) \quad \forall j \neq i$$

$$\underline{x}(k) \in \omega_i \quad k^{\text{th}} \text{ sample}$$

$$d_i(\underline{x}(k)) > d_j(\underline{x}(k)) \quad \forall j \neq i = 1, \dots, M$$

$$\underline{x}(k) \in \omega_i$$

$$d_i(\underline{x}) = \underline{w}_i^T \underline{x}(k)$$

$$d_i(\underline{x}(k)) < d_e(\underline{x}(k)) \Rightarrow e^{\text{th}} \text{ classifier is not correct}$$

Learning Rule:

$$\underline{w}_i(k+1) = \underline{w}_i(k) + c \underline{x}(k) \quad \rightarrow \text{این را زیاد کن}$$


$$\underline{w}_e(k+1) = \underline{w}_e(k) - c \underline{x}(k) \quad \rightarrow \text{این را کم کن}$$

$$\underline{w}_j(k+1) = \underline{w}_j(k) \quad j \neq i, e \rightarrow \text{این را تغییر نده}$$

$$\underline{w}_1 = \left\{ \begin{pmatrix} 0 \\ 0 \end{pmatrix} \right\}$$

$$\underline{w}_2 = \left\{ \begin{pmatrix} 1 \\ 1 \end{pmatrix} \right\}$$

$$\underline{w}_3 = \left\{ \begin{pmatrix} 1 \\ -1 \end{pmatrix} \right\}$$



$$\underline{w}_1(1) = \underline{w}_2(1) = \underline{w}_3(1) = \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix}$$

$$c = 1$$

$$d_i(\underline{x}) = \underline{w}_i^T \underline{x}$$

$$i = 1, 2, 3$$

Subject:

Year: Month:

Date: 48

$$* \underline{x}(1) = \begin{pmatrix} 0 \\ 0 \\ 1 \end{pmatrix} \in w_1$$

$$d_1(\underline{x}(1)) = d_2(\underline{x}(1)) = d_3(\underline{x}(1)) = 0$$

$$\text{ideal: } \begin{cases} d_1(\underline{x}(1)) > d_2(\underline{x}(1)) \rightarrow x \\ d_1(\underline{x}(1)) > d_3(\underline{x}(1)) \rightarrow x \end{cases}$$

$$\text{update: } \begin{cases} \underline{w}_1(2) = \underline{w}_1(1) + c \underline{x}(1) = \begin{pmatrix} 0 \\ 0 \\ 1 \end{pmatrix} \\ \underline{w}_2(2) = \underline{w}_2(1) - c \underline{x}(1) = \begin{pmatrix} 0 \\ 0 \\ -1 \end{pmatrix} \\ \underline{w}_3(2) = \underline{w}_3(1) - c \underline{x}(1) = \begin{pmatrix} 0 \\ 0 \\ -1 \end{pmatrix} \end{cases}$$

$$* \underline{x}(2) = \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix} \in w_2$$

$$\underline{w}_1^T(2) \cdot \underline{x}(2) = 1$$

$$\underline{w}_2^T(2) \cdot \underline{x}(2) = -1$$

$$\underline{w}_3(2) \cdot \underline{x}(2) = -1$$

$$\text{update: } \begin{cases} \underline{w}_1(3) = \underline{w}_1(2) - c \underline{x}(2) = \begin{pmatrix} -1 \\ -1 \\ 0 \end{pmatrix} \\ \underline{w}_2(3) = \underline{w}_2(2) + c \underline{x}(2) = \begin{pmatrix} 1 \\ 1 \\ 0 \end{pmatrix} \\ \underline{w}_3(3) = \underline{w}_3(2) - c \underline{x}(2) = \begin{pmatrix} -1 \\ -1 \\ 2 \end{pmatrix} \end{cases}$$

* ...

$$\underline{w}_1(8) = \underline{w}_1(7) = \begin{pmatrix} 0 \\ -2 \\ 0 \end{pmatrix} \rightarrow d_1(\underline{x}) = -2x_2$$

$$\underline{w}_2(8) = \underline{w}_2(7) = \begin{pmatrix} 2 \\ 0 \\ -2 \end{pmatrix} \rightarrow d_2(\underline{x}) = 2x_1 - 2$$

$$\underline{w}_3(8) = \underline{w}_3(7) = \begin{pmatrix} -2 \\ 0 \\ -2 \end{pmatrix} \rightarrow d_3(\underline{x}) = -2x_1 - 2$$

$$d_{12}(\underline{x}) = d_1(\underline{x}) - d_2(\underline{x}) = -2(x_1 + x_2) + 2$$

Subject :

Year :

Month :

Date :

Non-linear Classifier

*

linear •

$$h(\underline{x}) = \underline{v}^T \underline{x} + v_0$$

$$f(\eta_1, \eta_2, \sigma_1^2, \sigma_2^2)$$

$$\frac{\partial f}{\partial \underline{v}}, \quad \frac{\partial f}{\partial v_0}$$

non-linear •

$g(\underline{x}) \equiv$ General Discriminant Function

\underline{x}

$$g(\underline{x}) = \sum_{w_i}^{w_1} \phi$$

$$f(\eta_1, \eta_2, s_1^2, s_2^2)$$

$$\eta_i = E\{y(\underline{x}) | w_i\}$$

$$s_i^2 = E\{y^2(\underline{x}) | w_i\}$$

$c_i^2 =$ second order moment of y

$$= \int_{-\infty}^{+\infty} y^2(\underline{x}) \cdot p_i(\underline{x}) \cdot d\underline{x}$$

$\delta f \equiv$ variation of f due to variation of $g(\underline{x})$

$$\delta f = \frac{\partial f}{\partial s_1^2} \delta s_1^2 + \frac{\partial f}{\partial s_2^2} \delta s_2^2 + \frac{\partial f}{\partial \eta_1} \delta \eta_1 + \frac{\partial f}{\partial \eta_2} \delta \eta_2$$

Subject:

Year: Month: Date:

49

$$\delta \eta_i = \int \delta y \dots P_i(\underline{x}) \cdot d\underline{x}$$

$$\delta S_i^2 = \int 2 y(\underline{x}) \cdot \delta y(\underline{x}) \cdot P_i(\underline{x}) \cdot d\underline{x}$$

مطلوبت:

$$\delta f = 0$$

$$y = a_1 \frac{s P_1(\underline{x})}{s P_1(\underline{x}) + (1-s) P_2(\underline{x})} + a_2 \frac{(1-s) P_2(\underline{x})}{s P_1(\underline{x}) + (1-s) P_2(\underline{x})}$$

$$s = \frac{\frac{\partial f}{\partial s_1^2}}{\frac{\partial f}{\partial s_1^2} + \frac{\partial f}{\partial s_2^2}}$$

$$a_i = - \frac{\partial f / \partial \eta_i}{2 \partial f / \partial s_i^2}$$

• برای استناد از σ^2 داریم:

$$s_x^2 = \sigma_x^2 + \eta_x$$

• مشابهت با تانل نیز

$$q_1(\underline{x}) \geq q_2(\underline{x})$$

$$q_1(\underline{x}) - q_2(\underline{x}) \geq 0$$

$$y(\underline{x}) = a_1 \cdot q_1(\underline{x}) + a_2 \cdot q_2(\underline{x})$$

• نرم تابع گایز غیر صحتی " صحت دوم

$$\frac{1}{2} (\underline{x} - \underline{m}_1)^T \Sigma_1^{-1} (\underline{x} - \underline{m}_1) - \frac{1}{2} (\underline{x} - \underline{m}_2)^T \Sigma_2^{-1} (\underline{x} - \underline{m}_2) + \frac{1}{2} \ln \frac{|\Sigma_1|}{|\Sigma_2|} \geq \ln \frac{P_1}{P_2}$$

$h(\underline{x})$ \rightarrow متجه Σ ، m_i متجه

Subject:

Year:

Month:

Date:

نرم اهل پنج غایز لندہ غیر صحتی درجه دوم

$$h(\underline{x}) = \underline{x}^T [q_n] \underline{x} + \underline{v}^T \underline{x} + v_c \sum_{\omega_2}^{\omega_1} 0$$

$$f(\eta_1, \eta_2, \sigma_1^2, \sigma_2^2)$$


لروفنا n لاری باشد ما این لعداد ما را متراد تخمین زد:

$$\frac{n(n+1)}{2} + n + 1$$

• راه اول، نوشتن تابع درجه دوم، به تابع غایز دهند است و آنها را از هم جدا کرد

$$d_1^2(\underline{x}) = (\underline{x} - \underline{m}_1) \sum_1^{-1} (\underline{x} - \underline{m}_1)$$

$$d_2^2(\underline{x}) = (\underline{x} - \underline{m}_2) \sum_2^{-1} (\underline{x} - \underline{m}_2)$$



• تمرینات فصل 4

computer projects : 1, 2, 3, 4, 5 (a, b, d, e, f), hand out

problems : 1, 2, 3, 4, 5, 9

date : 1387, 9, 17

• کتابخانه

date : 1387, 9, 17 ... 9, 24 !!

book : 2, 3, 4 → Fakhrazad

classroom : et. all.

Subject:

Year: Month:



Date: 50

Non-linear Classifiers


x_1	x_2	class
0	0	False (-) : w_B
0	1	True (+) : w_A
1	0	True (+) : w_A
1	1	False (-) : w_B

x_1	x_2	class
0	0	F : w_B
0	1	T : w_A
1	0	T : w_A
1	1	T : w_A

OR vs XOR



شکل پرستون برای OR




$$h(x) = w^T x = [w_0 \quad \underline{w}]^T \begin{bmatrix} 1 \\ x_1 \\ x_2 \end{bmatrix} = w_0 + \underline{w}^T x$$

$$f(x) = x_1 + x_2 - \frac{1}{2} > 0$$

0	0	< 0
0	1	> 0
1	0	> 0
1	1	> 0

شکل پرستون برای XOR



$$f(x) = \sum_{i=0}^2 w_i x_i$$

$$u(x) = \begin{cases} 1 & , x > 0 \\ 0 & , x < 0 \end{cases}$$

Subject:

Year: Month: Date: ()

$$y_i = u_i (f_i(x)) \rightsquigarrow g_i(x)$$

step I:


موفقیت نسبت به پارامتر خط y_1

x_1	x_2	$y_1 = g_1(x)$	$y_2 = g_2(x)$
0	0	0	0
0	1	1	0
1	0	1	0
1	1	1	1


step II:

موفقیت نسبت به دو پارامتر خط
در تلاش: داخل خط و خارج خط

x_1	x_2	XOR
0	0	0
0	1	1
1	0	1
1	1	0




خطی جداپذیرند
علازه با خط استناد شده است



Firing Function

رکبتردی دو لایه:



PAPCO

Input Layer

Hidden Layer

Output Layer

Subject:

Year: Month: Date: 51

$$g_1(x) = x_1 + x_2 - \frac{1}{2}$$

$$g_2(x) = x_1 + x_2 - \frac{3}{2}$$

$$h(y) = y_1 - 2y_2 - \frac{1}{2}$$

$$= u(g_1(x)) - 2u(g_2(x)) - \frac{1}{2}$$


Two - Layer Perceptron

Two - Layer Feed Forward NN

فضای سه بعدی است یعنی

Multi - Layer Perceptron (MLP)

n-D, 2-class




hyper-cube!

n-D

p-D

1-D



فضای سه بعدی است XOR

$x_2 x_3$	00	01	11	10
0		1		1
1	1		1	



$g_1(x)$ → بیت اول

$g_2(x)$ → بیت دوم

$g_3(x)$ → بیت سوم

Subject:

Year: Month: Date: ()



Generalization

\underline{x}

$$\underline{y} = \begin{bmatrix} y_1 \\ y_2 \end{bmatrix} = \begin{bmatrix} f(g_1(x)) \\ f(g_2(x)) \end{bmatrix}$$

$f(\cdot) \equiv$ firing function \equiv activation function

generalized linear function:

$$f_i : \mathbb{R}^n \rightarrow \mathbb{R}^k$$

$$\begin{bmatrix} y_1 \\ \vdots \\ y_k \end{bmatrix}$$

$$g(\underline{x}) = w_0 + \sum_{i=1}^k w_i f_i(x_i)$$

2nd Order

$$g(\underline{x}) = w_0 + \sum_{i=1}^n w_i x_i + \sum_{i=1}^{n-1} \sum_{m=i+1}^n w_{im} x_i x_m + \sum_{i=1}^n w_{ii} x_i^2$$

$n=0$

$$\underline{y} = \underline{g}(\underline{x}) = [x_1 \quad x_2 \quad x_1 x_2 \quad x_1^2 \quad x_2^2]$$

$2=0$

Subject:

Year: Month: Date: 52


n -order $\rightarrow x_1, x_2, \dots, x_n$

$n=0 \rightarrow k = \frac{(n+r)!}{n! \times r!}$

XOR ✓


$\underline{y} = \begin{pmatrix} x_1 \\ x_2 \\ x_1 x_2 \end{pmatrix}$

$\underline{x} = (x_1, x_2)$	(0,0)	(0,1)	(1,0)	(1,1)
$\underline{y} = (y_1, y_2, y_3)$	(0,0,0)	(0,1,0)	(1,0,0)	(1,1,1)
	w_0	w_A	w_B	w_C



$P: h(y) = y_1 + y_2 - 2y_3 - \frac{1}{4} = 0$

$(0,0,0) \rightarrow h(0,0,0) < 0$ نیست



$h(y) = y_1 + y_2 - 2y_3 - \frac{1}{4} = 0$

$g(x) = x_1 + x_2 - 2x_1 x_2 - \frac{1}{4} = 0$

(RBF) Radial Basis Function Networks

$\Phi(\cdot) = f(\|x - c_i\|)$

distance function

$g(x) = w_0 + \sum_{i=1}^K w_i \cdot \Phi_i(\cdot)$

RBF های استیجابی معنی وجود دارد. آنجا که با آن کار کردیم و در آنجا یادگیری می‌کنیم.

Subject:

Year:

Month:

Date:

()

$$* f(x) = \exp\left(-\frac{1}{2\sigma_i^2} \|x - c_i\|^2\right)$$

$$g(x) = w_0 + \sum_{i=1}^k w_i \exp\left(-\frac{(x - c_i)^T (x - c_i)}{2\sigma_i^2}\right)$$


$$* f(x) = \frac{\sigma^2}{\sigma^2 + \|x - c\|^2}$$

XOR \checkmark

$$\underline{y} = g(x) = \begin{bmatrix} \exp(-\|x - c_1\|^2) \\ \exp(-\|x - c_2\|^2) \end{bmatrix}$$


$$c_1 = \begin{bmatrix} 1 \\ 1 \end{bmatrix} \quad c_2 = \begin{bmatrix} 0 \\ 0 \end{bmatrix}$$

x_1	x_2	y_1	y_2
0	0	0.135	1
0	1	0.368	0.368
1	0	0.368	0.368
1	1	1	0.135



$$g(\underline{y}) = y_1 + y_2 - 1 = 0$$

$$g(x) = \exp(-(x - (1))^\top (x - (1))) + \exp(-(x - (0))^\top (x - (0))) - 1 = 0$$



این تابع seed و البسته مستند (c_i) Locality
 می توان مقادیر c (برای x) و w (بجز w_0) را با الگوریتم جستجوی آزمون.

Subject:

Year: Month:

Date: 53

* Clustering → تعیین c_i


* Gradient → $J(\underline{x}, \underline{w}, \underline{c}, \sigma)$

$$\underline{w}(k+1) = \underline{w}(k) - \epsilon \nabla_{\underline{w}} J$$

$$\underline{c}(k+1) = \underline{c}(k) - \epsilon \nabla_{\underline{c}} J$$


$$\sigma(k+1) = \sigma(k) - \epsilon \nabla_{\sigma} J$$

(Decision Trees) روشهای تقسیم x



4-class

2-D



مسئله

- * مشکل تقسیم برای روشهای جدیدی
- * کندتر روشی برای تقسیم برای استفاده شد
- * اندازه‌های برابر
- * مبرهن بودن روشهای جدید

Subject:

Year:

Month:

Date:

(6 فصل) Non-Parametric Density Estimation *

$$P_i(x) \quad i = 1, \dots, M$$

* گاهی اوقات فرض می‌کنیم که توزیع ما صمیمیت و پارامتری است اما تخمین می‌زنیم

مثلاً Σ برای توزیع نرمال

* گاهی اوقات تنها از روی N نمونه مدل ساخته می‌شود و می‌خواهیم از روی نمونه آن توزیع را بسازیم

1-D

$$P(x) \sim \text{Volume}$$

$R \equiv \text{Region}$

$$\text{Prob}\{x \in R\} \equiv P = \int_R P(x) \cdot dx$$

n-D

$$\text{Prob}\{x \in R\} \equiv P = \int_R P(x) \cdot dx$$

n-integral

$P(x)$ is continuous over R

$$P = \int_R P(x') \cdot dx' \approx P(x) \cdot V$$

$V \equiv \text{volume enclosed by } R$

$x \equiv \text{a point in } R$

N samples

$$x_1, x_2, \dots, x_N$$

probability that k of N samples fall in R is estimated by:

PAPCO
$$P \approx \frac{k}{N}$$

Subject:

Year: Month: Date: 54

• از ترکیب در رابطه داریم:

$$\hat{P}(x) \cdot V = \frac{K}{N} \Rightarrow \hat{P}(x) = \frac{K}{N \cdot V}$$

$$= \frac{K_j}{N}$$


$$= \frac{P_j}{V}$$

$$\Rightarrow \hat{P}(x) = \frac{\int_R P(x) \cdot dx}{\int_R dx} \sim \text{smooth version of } P(x)$$

• با دلجیل کردن فاصله

- * $\hat{P}(x) \rightarrow P(x)$
- * ممکن است در بازه دقت نظر نداشته باشیم و خطای فزاینده حالت *spike*
- * در محدودیت نداشتن *dilemma* می سازد
- * بر این فاصله دلجیل کردن *bin* یا *cell* می گویند

• روش Histogram



x_1, \dots, x_N
bins

Area under the j^{th} bin (interval) =

Fraction of total # of samples (N) fall in that region =

$$\frac{K_j}{N}$$

$$\text{Height of the density} = \frac{\text{area}}{\text{width}} = \frac{K_j / N}{W_j} = \frac{K_j}{N \cdot W_j}$$

Subject:

Year:

Month:

Date:

()

تعداد Bin

* زیاد ← بچین زحمت از تابع توزیع
 * کم ← spike در لیست با جزییات

Rule of thumb *

N samples

$$\# \text{ of interval} = \sqrt{N}$$


* برای بیشترین بردن خطای مطلق

$$E \{ (P(x) - \hat{P}(x))^2 \}$$

$$\# \text{ of interval} = \sqrt[3]{N}$$

2-D

$P(x)$ is continuous over R



5-D

n = 5

10 intervals

10^5 histogram bins → lots more samples requires

• می توان از بازه های نابرابر استفاده کرد




Parzen Window *

این روش، بر نحوه دایب kernel اختتامی کند که در آینه می گیرد.
 برای اینکه در برینله اندازه توزیع تخمین زده شود، مقدار kernel می موجود در
 آنجا به جمع می کنند.

convolution

$$x(t) * h(t) = \int_{-\infty}^{+\infty} x(\tau) h(t-\tau) d\tau$$

1-D




$h \rightarrow \delta \Rightarrow k(n) \rightarrow \delta(n)$

$x(t) * \delta(t) = x(t)$

له بین تخمین به سمت مقدار واقعی می رود.

Bias: how close is the estimate to the true value?
 Variance: how much does the estimate change for different runs?



Trade off: bias - variance

Subject:


Year:

Month:

Date: ()

• در این پارزن، جهت زیرین kernel، بزرگ است
 برای یک sample، بزرگ kernel، بزرگ است
 توزیع kernel، بزرگ است، و توزیع در آن بزرگ است
 این تابعی توزیع مستطیلی، لوسی، ... است

kernel ← بزرگ : Spiky
 ← بزرگ : Smooth




$$MSE(P_{KDE}) = \text{Bias}^2 + \text{Variance}$$

• انواع kernel های مختلف به شرح زیر

I) Rectangular

$$k(x) = \begin{cases} \frac{1}{2} & |x| < 1 \\ 0 & |x| > 1 \end{cases}$$



II) Triangular

$$k(x) = \begin{cases} 1 - |x| & |x| < 1 \\ 0 & \text{o.w.} \end{cases}$$

III) Biweight

$$k(x) = \begin{cases} \frac{15}{16} (1 - x^2)^2 & |x| < 1 \\ 0 & \text{o.w.} \end{cases}$$

IV) Normal

$$k(x) = \frac{1}{\sqrt{2\pi}} \exp\left(-\frac{x^2}{2}\right)$$

Subject:

Year: Month:

Date: 56

V) Bartlett-Epanechnikov

$$K(x) = \begin{cases} \frac{3}{4} (1 - \frac{x^2}{5}) / \sqrt{5} & |x| < \sqrt{5} \\ 0 & \text{o.w} \end{cases}$$

دستی چندجبری

I.) Normal


$$K(x) = \frac{1}{(\sigma x)^{n/2}} \exp \left\{ -\frac{1}{2} x^T x \right\}$$

II.)

$$K(x) = \frac{(1 - x^T x)^{(n+2)} \text{ for } |x| < 1}{2 C_p}$$

$$C_p = \pi^{n/2} / \Gamma \left(\frac{n}{2} + 1 \right) \sim \text{volume of sphere in } n\text{-D}$$

d



base = 3 مثلث

$\hat{p}(x)$

area of each triangle = $\frac{1}{3}$

height = $\frac{2}{9}$

دستی انتخاب کنید

Minimize Integral of Square Error

MISE استاندارد

توزیع نرمال kernel نرمال

استاندارد h نسبت

$$h_{opt} = 1.06 \times \sigma \cdot N^{-1/5}$$

$$h_{opt} = \arg \min_h \{ MISE(\hat{p}_{KDE}(x)) = \arg \min_h \{ E | \dots \} \}$$

* یک معیار دیگر A است

$$A = \min \left\{ \sigma, \frac{IQR}{1.34} \right\}$$

$$h_{opt} = 0.9 \times A \times N^{-1/5}$$

IQR = بازه‌های از پرانندگی داده که بین 0.25 تا 0.75 داده در آن باشد

* h های مختلف در داده‌های توزیع‌شده ممکن است مناسب باشند

* kernel: راه‌صورت ضرب تعدادی kernel مختلف می‌توان نوشت که هر کدام ممکن است h های توزیع‌شده داشته باشند. هر کدام از این زیر kernel ها درجه یک هستند. فرض استقلال متغیرها در این روش هم نیست.

* می‌توان از معیارهای دیگری نیز استفاده کرد که جای MISE، سعی در پیدا کردن K کند

• اگر فرض استقلال متغیرها می‌باشد $P(x)$ را داشته باشیم می‌توان آنرا اینگونه نوشت:

$$P(x) = \prod_{i=1}^n P(x_i)$$

Naive Bayes Classifier

K-Nearest Neighbor

• پرانندگی نقاط در یک حلقه کلاس نیست

• سعی می‌کنیم اندازه bin را با توجه به حجم نمونه در نظر بگیریم

• در Parzen Window، اندازه bin ثابت است و می‌بینیم چگونه در آن می‌کند

• در KNN، تعداد نمونه در هر bin ثابت است و می‌بینیم اندازه آن چگونه باید باشد

Subject:


Year: Month: Date: 57

$$P(x) = \frac{k}{N \cdot V}$$

$$n = D$$

$$P(x) = \frac{k}{N \cdot C_n \cdot R^n(x)}$$


$$C_n = \frac{\pi^{n/2}}{(n/2)!} = \frac{\pi^{n/2}}{\Gamma(n/2+1)}$$



$$C_1 = 2$$

$$C_2 = \pi$$

$$C_3 = \frac{4\pi}{3}$$



پارامتری کم



پارامتری زیاد

Local Noise

* حالت Spiky ← چنانچه $R(x)$ متن پذیر نیست

* هر چه قدر نمونه بیشتر باشد، ترتیب کمتر است

* k بیشتر به تعداد نمونه، مقدار opt دارد ← $k < opt$: زود خرابی

* $k > opt$: بی خیالی

* Q_i همین توزیع مانند بیز

$$l(x) = \frac{P_1(x)}{P_2(x)}$$

$$P(x|w_i) = \frac{k_i}{N_i \cdot V}$$

$$P(w_i) = \frac{N_i}{N}$$

$$P(w_i|x) = \frac{P(x|w_i) P(w_i)}{P(x)} = \frac{k}{N} \rightsquigarrow \text{KNN Classifier}$$

Subject:

Year .

Month .

Date .

()

KNN Classifier

- اول k تا از نزدیک ترین همسایه های x را انتخاب می کنیم
- می بینیم هر کدام از این همسایه ها متعلق به کدام کلاس است.
- بیشترین تعداد را به عنوان کلاس x انتخاب می کنیم

Lazy Learner \leftarrow KNN

- نیاز به تمام داده های یادگیری دارد تا دردی جدید را طبقه بندی کند.
- به موقع لازم بود طبقه بندی را انجام می دهد.
- بر خلاف Statistical PR یا Neural PR

نیاز به حافظه زیاد

حجم حساباتی کم

Curse of Dimensionality

k نزدیک \leftarrow جنیات ازین می رود

محاسبات بیشتر

k کوچک \leftarrow Smoothness از دست می رود

Independent Bayes, Naive Bayes, Idiot's Bayes *


$$\underline{x} = \begin{bmatrix} x_1 \\ x_2 \\ \vdots \\ x_n \end{bmatrix} \rightarrow x_i \text{ متغیر}$$

$$P(\underline{x}) = \prod_{i=1}^n P(x_i)$$

• مستقل

$x_i \rightarrow k$ bin

$x \rightarrow n \times k$ bin \rightarrow متغیر



independent model •

$$P(\underline{x}) \sim \left\{ \prod_{r=1}^n \frac{n(x_r) + 1/C_r}{N(r) + 1} \right\}^B$$

$x_r \equiv r^{\text{th}}$ Component of \underline{x}

$n(x_r) \equiv$ # of samples with value x_r on variable r

$N(x_r) \equiv$ # of observation on variable r (due missing value)

$C_r \equiv$ # of cells on variable r

$B \equiv$ "Association Factor"

\rightarrow non-redundant information! متناسب

$B=1 \rightarrow$ روش متغیر

$B < 1 \rightarrow$ "متغیر" $\rightarrow 0.5, 0.8, \dots$

Subject: _____

Year: _____

Month: _____

Date: _____

()

Lancaster Model

$P(x)$

ی خواهیم بحث کنیم
اجزای دهیم که آیا در جوابی بین ما
interaction رخ داده است

$n-D$

x

$$P(x) = \left[\sum_{\substack{i,j \\ i < j}} \frac{P(x_i, x_j)}{P(x_i) \cdot P(x_j)} - \left[\binom{n}{2} - 1 \right] \right] P_{ind}(x)$$

$$P_{ind}(x) = \prod_{k=1}^n P(x_k)$$

$S \equiv$ order of interaction = 2

$$P(x_i, x_j) = \frac{n(x_i, x_j) + \frac{1}{c_i \times c_j}}{N(i, j) + 1}$$

$n(x_i, x_j) \equiv$ # of samples with value x_i, x_j

$N(x_i, x_j) \equiv$ # of observation on variable i & j

$C_r \equiv$ # of cells in variable r

$$\begin{bmatrix} x_1 \\ x_2 \end{bmatrix} \quad \begin{bmatrix} x_1 \\ * \end{bmatrix} \quad \begin{bmatrix} * \\ x_1 \end{bmatrix}$$

$$\begin{matrix} \checkmark & \checkmark & \checkmark & n \\ \checkmark & \times & \times & N \end{matrix}$$

Maximum weight Dependence Tree *

$2-D$

Subject:

Year: _____ Month: _____ Date: 59

$$P_i(x) = P(x | w_i) = \frac{P(x; w_i)}{P(w_i)}$$


$$\Rightarrow P(x; w_i) = P(w_i) \times P(x | w_i)$$

$t \equiv$ tree

$$P^t(x) = \prod_{i=1}^n P(x_i | x_{j(i)}) \quad \text{ترتیبی ندارد که بیشتر باشد}$$
$$= \prod_{i=1}^n P(x_{m_i} | x_{j(m_i)})$$

$$j(i) = \text{parent}(i)$$

$$P^t(x) = P(x_1) \cdot P(x_2 | x_1) \cdot P(x_3 | x_2) \cdot P(x_4 | x_2) \cdot P(x_5 | x_4) \\ \cdot P(x_6 | x_4) \cdot P(x_7 | x_4) \cdot P(x_8 | x_7)$$



• به دنبال درختی هستیم که کمترین نانش $P^t(x)$ باشد.

$$x_1 \rightarrow \text{root} : P(x_1 | x_0) = x_1$$

Subject:


Year:

Month:

Date: ()

ادامه مثال

$$P^t(x) = P(x_4) \cdot P(x_1|x_2) \cdot P(x_3|x_2) \cdot P(x_2|x_4) \cdot P(x_5|x_4) \cdot P(x_6|x_4) \cdot P(x_7|x_4) \cdot P(x_8|x_7)$$



• تعداد تعداد درختها

$$n^{n-2}$$

• اگر هر متغیر با تسلسل داشته باشد

$$\# \text{ of cells} = h(h-1)(n-1) + hn$$

• معیاری مورد نیاز است تا نزدیکترین را اندازه گیری کند

Kullback Leibler

• معیاری از شاخص KL استفاده می کند

$$D_{KL}(P(x), P^t(x)) = \int P(x) \cdot \log\left(\frac{P(x)}{P^t(x)}\right) \cdot dx$$

$$D_{KL} \rightarrow > 0$$

$$= 0 \Rightarrow P(x) = P^t(x) \Rightarrow \text{یکسانترین}$$

$$D_{KL}(P(x), P^T(x)) \leq D_{KL}(P(x), P^t(x))$$

$$\forall t \neq T$$

این تابع cross entropy و گامش می دهد. مقدار entropy غیر قطعی
 موجود در تابع را نشان می دهد.

Subject:

Year: Month: Date: 60

Entropy •

$\{X_1, X_2, \dots, X_m\}$

$P_i = \text{Prob}\{X_i\} \quad i=1, \dots, m$

Entropy: $H_2 = - \sum_{i=1}^m P_i \log_2 P_i$ bits

□

X_0, X_1, \dots, X_7

$P_i = \frac{1}{8}$

$H = 3 \rightarrow$ # of bits to represent symbols


□

X_0, X_1, \dots, X_7

$P_i = 0 \quad i=0, \dots, 6$

$P_7 = 1$

$H = 0 \rightarrow X_7$ certainly occurs = no uncertainty



$P(x), q(x)$

$x \sim$ discrete

$$D_{KL}(P(x), q(x)) = \sum_x q(x) \ln \frac{q(x)}{P(x)}$$

Subject:

Year:

Month:

Date:

()

• مقادیر D_{KL}

$$D_{KL} \geq 0$$

$$D_{KL} = 0 \iff q(x) = p(x)$$

• Mutual Information (MI)

different variables

$$p(x)$$

$$q(y)$$

$$I(p, q) = H(p) - H(p|q)$$

مقدار عدم قطعیتی است که از مقدار کل استفاده می شود وقتی که ما یک توزیع را با بقیه

$$I(p, q) = H(p) - H(p|q)$$

$$= \sum_{x, y} r(x, y) \log_2 \frac{r(x, y)}{p(x) \cdot q(y)}$$

$r(x, y) \equiv$ joint distribution of x, y

MI نشان می دهد که دو توزیع چند از هم مستقل هستند

$$MI \geq 0$$

$$MI = 0 \iff \text{independence}$$

$$P^t(x) = \prod_{i=1}^n P(x_i | x_{j(i)})$$

هر مشاهده در جهت دارای وزن است که این وزن معادل MI بین پدر و فرزند است
و وقتی مناسب است که مجموع وزنها آن بیشینه باشد.

Subject:

Year: _____ Month: _____ Date: 6/1

$$W = \sum_{i=1}^n I(X_i, X_{j(i)})$$

$$W \sim \max \Rightarrow D_{KH} \sim \min$$

• اظہارِ رسم تولید درخت

max weight dependence tree (MWD.T)

max weight spanning tree (MWST)

ایک گراف کامل تبدیل می دهیم هر یال آن MI بین دو متغیر اجزا را میزند
بین آن MST میگذرد.

$$\text{find all weights} = \binom{n}{2} = \frac{n(n-1)}{2}$$

$$\text{find minimum spanning tree} : O(n^2) \Rightarrow O(n^2)$$

رتبه سری چهارم

Density Estimation

1. Histogram
2. Parzen Method
 - * Rectangular
 - * Gaussian
 - * Triangular
 - * Product Form
3. KNN Method
4. Independence Tree

Subject: _____

Year. Month. Date. ()

I. Generate Data

* Normally Distributed 1D: $\{\mu, \sigma^2\}$ 2D: $\{m, [\Sigma]\}$

* Uniform

II. Do Estimation

III. Visualize Data & PDF {original, estimated}


IV. Provide Interface

Subject:

Year. Month. Date. 62

Feature Reduction *

$$\begin{array}{ccc}
 n-D & n \times 1 & \underline{x} \quad \underline{x} \\
 m-D & m \times 1 & \underline{y} \quad \underline{y}
 \end{array}
 \quad \left. \vphantom{\begin{array}{ccc} n-D & n \times 1 & \underline{x} \quad \underline{x} \\ m-D & m \times 1 & \underline{y} \quad \underline{y} \end{array}} \right) m < n$$



Feature Selection

Feature Extraction

$$\underline{y} = [a]^T \underline{x}$$

$m \times 1 \qquad \qquad n \times 1$

$$[a] = n \times m$$

• کاهش ارزیابی برای کاهش نسبت به دیگری

Feature selection \Rightarrow subset

Feature extraction \Rightarrow function

$S_m \equiv$ all subsets

$A \equiv$ all transformation

$$J(\tilde{S}_m) = \max_{s \in S_m} J(s)$$

$$J(\tilde{A}) = \max_{A \in A} J(A(x))$$

Subject:

Year:

Month:

Date: ()

• تعداد ارزشهای ممکن

n feature

m select

$$\binom{n}{m} = \frac{n!}{m! (n-m)!}$$

$$n = 25 \quad m = 10$$

$$\# = 3,268,760$$

Feature Selection Criterion

1. Design Classifier

$$2. \frac{n-D}{m-D} \quad \frac{N_1 \text{ sample}}{N_1} \quad \frac{N_2}{N_2}$$

$$\frac{P_1(y)}{P_2(y)}$$

Use Distance Functions...

* Divergence

$$J_D(w_1, w_2) = \int_{-\infty}^{+\infty} [P(x|w_1) - P(x|w_2)] \times \ln \frac{P(x|w_1)}{P(x|w_2)} \times dx$$

class 1: $N(\underline{m}_1, [\Sigma]_1)$

class 2: $N(\underline{m}_2, [\Sigma]_2)$

$$J_D(w_1, w_2) = \frac{1}{2} (\underline{m}_2 - \underline{m}_1)^T ([\Sigma]_1^{-1} + [\Sigma]_2^{-1}) (\underline{m}_2 - \underline{m}_1) + \text{Tr} \left\{ [\Sigma]_1^{-1} [\Sigma]_2 + [\Sigma]_1 [\Sigma]_2^{-1} - 2[I] \right\}$$

* Chernoff

$$J_C(\cdot) = -\log \int P^s(x|w_1) \cdot P^{(1-s)}(x|w_2) \cdot dx$$

* Bhattacharyya

$$J_B(\cdot) = -\log \int [P(x|w_1) - P(x|w_2)]^{1/2} \cdot dx$$

* Patrick - Fisher

$$J_P(\cdot) = \int [P(x|w_1) \cdot P_1 - P(x|w_2) \cdot P_2]^2 \cdot dx$$

* KL

• راههای جستجوی زیرگرم؟
Branch & Bound

* روشی با خاصیت monotonic داشته باشد، یعنی:

$$X \subset Y \Rightarrow J(X) < J(Y)$$

یعنی هر چه feature اضافه کنیم، مقدار J زیاد شود.

* روش optimum است.

* درخت تئلی می دهد.

* از نوع Top-Down است، یعنی از اصل feature شروع می کند و سپس

با بینه ادامه دهد.

* شاخه های اهدتار subset را در خود دارد تولید نمی کند.

Subject:

Year:

Month:

Date:


()

5 Features




Select 3 Features

construct a tree



criteria function اعمال سنجار




Start @ (*) : (1, 2, 3) → J = 77.2

back track : (1, 2, 5) → J = 80.1

$$J = (\underline{m}_1 - \underline{m}_2)^T \left(\frac{\Sigma_1 + \Sigma_2}{2} \right)^{-1} (\underline{m}_1 - \underline{m}_2)^T$$

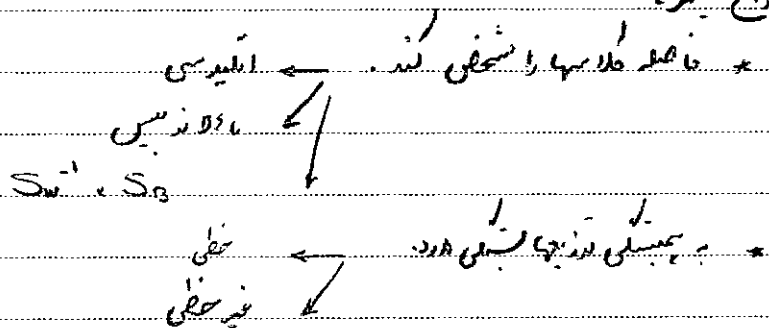
علت اینکه پایین نمی رود (در عمل زیر دیتاها را نمی سازد) اینست که نرد و والد آنها سنجار
 و آن گویا از سنجار بچینه ما باشد پس طبق خاصیت monotonic نرد و والد آنها سنجار
 نمره از خودشان می باشد و نمی تواند J را بهتر کند



انواع تابع ارزیابی

- 1. Filter → Information Content
- 2. Wrapper → Pattern Classifier

انواع فیلتر



استراتژی های جستجو

- ... Branch & Bound , Exhaustive ← Exponential *
- ... Simulated Annealing , Genetic ← Sequential *
- ... ← Randomized *

Naive Sequential Feature Sel.


X_1, \dots, X_n
 select m feature
 use criteria function J
 rank features regarding to J and independently : $J(X_i)$
 select m upper feature
 suitable for all independent feature set

* اگر لازم است سفل نباشند این جواب مناسب نیست ولی اگر تمام Feature لازم است سفل باشد، بهترین جواب را بدست می دهد.

(SFS) Sequential Forward Sel.

* انتخاب این ویژگیها از مجموعه Feature در به صورت Bottom-Up

1. Start with empty set Y_0
2. Add next best feature maximizing $J(Y_0 + X_i)$



Empty Feature Set

* سفل

* سوال این است که وقتی یک Feature انتخاب شد آیا می توان آنرا حذف کرد.

Full Feature Set

* در برخی جای الگوریتم وقتی Feature به تعداد مورد نظر را شنیم می توان الگوریتم را قطع کرد
* برای سفل که تعداد کمی Feature مورد نیاز است مناسب است

(SBS) Sequential Backward Sel.

* انتخاب این ویژگیها به صورت Top-Down

1. Start with full set $Y_0 = X$
2. Remove the features causing less decrease in criteria

* سوال: قابلیت بازگشت Feature حذف شده در جدول وجود ندارد
* برای سفل که تعداد کمی Feature مورد نیاز زیاد

Subject:

Year:

Month:

Date:

65

(LRS) Plus - L Minus R Sel.

* در هر مرحله L اضافه و R حذف می کنیم.

1. Depend on L or R start $Y = \emptyset / X$

2. Add L and remove R, ...

(BDS) Bidirectional Search

SFS + SBS

* برای ظاهر Feature اضافه کنید و بر ر نظر کنید که برای آن حذف کرده باشد.

(SFFS) Sequential Floating Sel.

Subject:

Year:

Month:

Date:

()

(chapter 9) Feature Extraction for Signal Representation *

• ربط پیدا کردن بهترین feature های نمایش سیگنال دیجیتال از دست دادن اطلاعات

$$\underline{x} = Y_1 \underline{a}_1 + Y_2 \underline{a}_2 + \dots + Y_m \underline{a}_m + \dots + Y_n \underline{a}_n$$

$$\underline{\tilde{x}} = Y_1 \underline{a}_1 + Y_2 \underline{a}_2 + \dots + Y_m \underline{a}_m$$

$$= [\underline{a}_1 \ \underline{a}_2 \ \dots \ \underline{a}_m] \begin{bmatrix} Y_1 \\ Y_2 \\ \vdots \\ Y_m \end{bmatrix}$$

$$m \rightarrow n \Rightarrow \underline{\tilde{x}} \rightarrow \underline{x}$$

• خصوصیات برداری پایه (u_i)

orthonormal

$$\underline{a}_i^T \underline{a}_j = \begin{cases} 1 & i=j \\ 0 & i \neq j \end{cases}$$

$$\underline{\tilde{x}} = [\underline{a}]_m \underline{y}$$

$$[\underline{a}]_m = [\underline{a}_1 \ \underline{a}_2 \ \dots \ \underline{a}_m]$$

to find Y_i

$$\underline{a}_i^T \underline{x} = Y_1 \underline{a}_i^T \underline{a}_1 + \dots + Y_i \underbrace{\underline{a}_i^T \underline{a}_i}_1 + \dots + Y_m \underline{a}_i^T \underline{a}_m$$

$$Y_i = \underline{a}_i^T \underline{x}$$

• حالت کلی

$$\underline{y} = [\underline{a}]_m^T \underline{\tilde{x}}$$

$$\binom{n}{m}$$

• چون بهترین زیر مجموعه $[u]$ مای خواهم نیاز به شاخص داریم
 این شاخص، شاخص خطا خواهد بود:

$$\underline{\epsilon} = \underline{x} - \tilde{\underline{x}} = \sum_{j=m+1}^n y_j \underline{u}_j$$

MSE

$$\mathcal{E} = E \{ \|\underline{\epsilon}\|^2 \} = E \{ \|\underline{x} - \tilde{\underline{x}}\|^2 \} = E \{ \underline{\epsilon}^T \underline{\epsilon} \}$$

$$\mathcal{E} = \sum_{j=m+1}^n E \{ y_j^2 \}$$

$$y_j^2 = y_j \cdot y_j = (\underline{u}_j^T \underline{x}) (\underline{u}_j^T \underline{x})$$

$$E \{ y_j^2 \} = \underline{u}_j^T E \{ \underline{x} \underline{x}^T \} \underline{u}_j$$

$$= \underline{u}_j^T [R] \underline{u}_j$$

↳ correlation matrix of \underline{x}

$$\mathcal{E} = \sum_{j=m+1}^n \underline{u}_j^T [R] \underline{u}_j$$

• پس سئو تبدیل می‌شود به مینه سازی

$$\mathcal{E} = \sum_{j=m+1}^n \underline{u}_j^T [R] \underline{u}_j$$

بفرض

$$\underline{u}_i^T \underline{u}_j = \begin{cases} 1 & i=j \\ 0 & i \neq j \end{cases}$$

$$\mathcal{E}' = \sum_{j=m+1}^n \underline{u}_j^T [R] \underline{u}_j + \sum_{j=m+1}^n \lambda_j (1 - \underline{u}_j^T \underline{u}_j)$$

↳ Lagrange multipliers

Subject:

Year:

Month:

Date:

()

$$\frac{\partial \mathcal{E}'}{\partial \underline{u}_j} = 2 ([R] \underline{u}_j - \lambda_j \underline{u}_j) = 0$$

$$[R] \underline{u}_j = \lambda_j \underline{u}_j$$

↳ eigen vector & eigen value

پس برای تعیین کردن \mathcal{E}' ، \underline{u}_i و λ_i سردارهای درشت $[R]$ باشد.

$$\bar{x}_m = \gamma_1 \cdot \underline{u}_1 + \dots + \gamma_m \cdot \underline{u}_m + \sum \mathcal{E} \{ \gamma_i \} \underline{u}_j$$

$$[\Sigma] \underline{z}_j = \lambda_j \cdot \underline{u}_j$$

(notation)

$$[R]_{n \times n} \longrightarrow \lambda_i \text{ in } n$$

ی خواهیم λ_i m یا n داریم

$$\mathcal{E} = \sum \lambda_i$$

پس کوچکترین λ_i را انتخاب می‌کنیم

حالت λ_i های باقی مانده \underline{u}_i را داریم

این تبدیل KL - transformation معروف است.

Karhunen - loeve Transformation

$$\underline{y} = [u]^T \underline{x}$$

$$[u] = [u_1 \dots u_m] = [\text{eigen vectors of } [R]]$$

Subject:

Year: Month: Date: 67

$$\underline{X} \quad n \times 1$$

$$\underline{X} = Y_1 \underline{u}_1 + \dots + Y_n \underline{u}_n$$

$$\underline{\tilde{X}} = Y_1 \underline{u}_1 + \dots + Y_m \underline{u}_m \quad m < n$$

$$\underline{\varepsilon} = \underline{X} - \underline{\tilde{X}}$$

$$\underline{\varepsilon} = \sum_{i=1}^m [\underline{u}_i]^T [R] [\underline{u}_i]$$

$$\underline{u}_i \cdot \underline{u}_j = \begin{cases} 1 & , i=j \\ 0 & , i \neq j \end{cases}$$

$$[\underline{u}] = [\underline{\phi}_1 \quad \underline{\phi}_2 \quad \dots \quad \underline{\phi}_m] \sim Kh$$

Pattern Recognition, ص. 61 *

$$\omega_1, \dots, \omega_m$$

$$\underline{X}_i^i \quad i=1, \dots, m$$

$$\underline{X}_i^i = \sum_{j=1}^m Y_j^i \cdot \underline{\phi}_j$$

مراحل.

1. Find correlation matrix [R]

$$[R] = \sum_{i=1}^M P(\omega_i) \cdot E \{ \underline{X}_i \underline{X}_i^T \}$$

2. Obtain the eigenvalues & eigenvectors of [R]

$$3. [A] = [\underline{\phi}_1 \quad \dots \quad \underline{\phi}_m]$$

4. Transformation


Subject:

Year:

Month:

Date:

()



• $\in \omega_1$

○ $\in \omega_2$

ω_1	ω_2
$x_{11} = (0, 0, 0)^T$	$(0, 0, 1)^T = x_{21}$
$x_{12} = (1, 0, 0)^T$	$(0, 1, 0)^T = x_{22}$
$x_{13} = (1, 0, 1)^T$	$(0, 1, 1)^T = x_{23}$
$x_{14} = (1, 1, 0)^T$	$(1, 1, 1)^T = x_{24}$

x_{ij} $\begin{cases} \rightarrow i = \text{class \#} \\ \rightarrow j = \text{sample \#} \end{cases}$

$$[R] = \sum_{i=1}^2 P_i \{x_i; x_i^T\}$$

$$= \frac{1}{2} [R_1] + \frac{1}{2} [R_2]$$

$$= \frac{1}{8} \left(\sum_{j=1}^4 x_{1j} x_{1j}^T + \sum_{j=1}^4 x_{2j} x_{2j}^T \right)$$

$$= \frac{1}{4} \begin{bmatrix} 2 & 1 & 1 \\ 1 & 2 & 1 \\ 1 & 1 & 2 \end{bmatrix}$$

$$|[R] - \lambda[I]| = 0 \begin{cases} \rightarrow \lambda_1 = 1 \rightarrow \phi_1 = \frac{1}{\sqrt{3}} \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix} \\ \rightarrow \lambda_2 = 1/4 \rightarrow \phi_2 = \frac{1}{\sqrt{6}} \begin{pmatrix} 2 \\ 1 \\ -1 \end{pmatrix} \\ \rightarrow \lambda_3 = 1/4 \rightarrow \phi_3 = \frac{1}{\sqrt{2}} \begin{pmatrix} 0 \\ 1 \\ -1 \end{pmatrix} \end{cases}$$


حل از میان λ انتخاب می‌کنیم.

$$[\Phi]_{3 \times 2} = \begin{bmatrix} \frac{1}{\sqrt{3}} & \frac{1}{\sqrt{6}} \\ \frac{1}{\sqrt{3}} & \frac{1}{\sqrt{6}} \\ \frac{1}{\sqrt{3}} & \frac{1}{\sqrt{6}} \end{bmatrix} \Rightarrow Y = [\Phi]^T X$$

$\begin{matrix} 2 \times 1 & 2 \times 3 & 3 \times 1 \end{matrix}$

Subject:

Year: Month: Date: 68



MSE = $\frac{1}{4}$: خطای MSE برابر eigenvalue است که اندکتر است پس
 حال اگر خواهیم به فضای یک بعدی برویم

1-0

$$\lambda_1 = 1$$

$$\rightarrow \text{MSE} = \frac{1}{4} + \frac{1}{4} = \frac{1}{2}$$

$$\phi_1 = \frac{1}{\sqrt{3}} \begin{pmatrix} 1 \\ 1 \\ 1 \end{pmatrix}$$

$$[u] = [\phi_1]$$

$$y_{11} = 0 \rightarrow y_{11} = \phi_1^T x_{11} = \left[\frac{1}{\sqrt{3}} \quad \frac{1}{\sqrt{3}} \quad \frac{1}{\sqrt{3}} \right] \begin{bmatrix} 0 \\ 0 \\ 0 \end{bmatrix} = 0$$

$$y_{12} = \frac{1}{\sqrt{3}}$$

* انتاب

$$\underline{x} = \sum_{i=1}^m y_i \phi_i = [\phi] \underline{y}$$

$$\hat{\underline{x}}(m) = \sum_{i=1}^m y_i \phi_i + \sum_{i=m+1}^n b_i \phi_i \quad \text{انتاب}$$

$$\underline{\Delta}(m) = \underline{x} - \hat{\underline{x}}(m)$$

$$= \sum_{i=m+1}^n (y_i - b_i) \phi_i$$

$$\bar{E}^2 = \sum_{i=m+1}^n E \{ (y_i - b_i)^2 \}$$

$$\frac{\partial \bar{E}^2}{\partial b_i} = 0 \rightarrow b_i^* = E \{ y_i \} \cdot \phi_i^T \cdot E \{ x \}$$

bi و E^2 را محاسبه می کنیم ...

Subject:

Year:

Month:


Date:

$$\bar{x}^2 = \sum_{i=1}^n \phi_i^T [\Sigma]_x \phi_i$$


مثالیه : به اولی نگاه کنید : b : در وزن همزمان به جای $[\Sigma]_x$ بگذار $[R]$ جهت آمده است

mean $\{x\} = 0 \rightarrow [\Sigma]_x = [R]$



mean $\{x\} \neq 0 \rightarrow [\Sigma]_x$ better ✓



$$\phi_i \cdot \phi_j = \begin{cases} 1 & , i=j \\ 0 & , i \neq j \end{cases}$$



ϕ_1 ← به خاطر وجود m_1 است
در جهت طولترین تغییر است.



(A): $[\Sigma] = [R] = \frac{1}{4} \sum_{i=1}^4 x_i x_i^T = \begin{bmatrix} 10 & 6 \\ 6 & 10 \end{bmatrix}$

(B): $[\Sigma] = \begin{bmatrix} 10 & 6 \\ 6 & 10 \end{bmatrix}$

(A) $\lambda_1 = 5$

$\lambda_2 = 0$

(B) $\lambda_1 = 4$

$\lambda_2 = 1$

$\phi_1 = \left(\frac{1}{\sqrt{2}} \quad \frac{1}{\sqrt{2}} \right)^T$



$\phi_2 = \left(\frac{1}{\sqrt{2}} \quad -\frac{1}{\sqrt{2}} \right)^T$

$\phi_1 = \left(\frac{1}{\sqrt{2}} \quad \frac{1}{\sqrt{2}} \right)^T$

$\phi_2 = \left(\frac{1}{\sqrt{2}} \quad -\frac{1}{\sqrt{2}} \right)^T$

$\Rightarrow \epsilon = 0$

$\Rightarrow \epsilon = 1 = \frac{1}{4} (\sqrt{2}^2 + \sqrt{2}^2)$



فشارده سازی به تبدیل K ها

بهترین انرژی در کمترین ضرایب وجود دارد

والسببه به Data - چنان به $[\Sigma]$ نیاز دارد

به همین دلیل از آن استفاده نمی شود (MPEG, JPEG)

به جای آن از تبدیلهای نزدیک به همینه مانند تبدیل کسینوسی استفاده می شود

$$\epsilon = \sum_{i=m+1}^n \lambda_i$$

جای اینله بایسیم λ_i می که انرژی داریم چه نسبتی از کل اطلاعات را در خود دارد، آنرا بر میال می کشند، با اینا بر میزان اطلاعات از دست رفته نتیجه می سنند

$$\mu_i = \frac{\lambda_i}{\sum_{j=1}^n \lambda_j}$$

Subject:

Year:

Month:

Date:

()

$$[\Sigma]_y = [\Phi]^T [\Sigma]_x [\Phi] = [\lambda]$$

اینس نظری

$$\begin{aligned} \text{tr}([\Sigma]_y) &= \text{tr}([\Phi]^T [\Sigma]_x [\Phi]) \\ &= \text{tr}([\Sigma]_x [\Phi] [\Phi]^T) \\ &= \text{tr}([\Sigma]_x [I]) \\ &= \text{tr}([\Sigma]_x) \end{aligned}$$

این رابطه بزرگترین نبردهای H دست می آید:

$$\mu_i = \frac{\lambda_i}{\text{tr}[\Sigma]_x}$$

(Scatter Measure

*) ساختن پراکندگی

$$\begin{aligned} \bar{d}_x^2 &= E \{ (\text{between sample distance}) \} \\ &= E \{ \| \underline{x}_i - \underline{x}_j \|^2 \} \\ &= E \{ (\underline{x}_i - \underline{x}_j)^T (\underline{x}_i - \underline{x}_j) \} \\ &= E \{ \underline{x}_i^T \underline{x}_i + \underline{x}_j^T \underline{x}_j \} - E \{ \underline{x}_i^T \underline{x}_j + \underline{x}_j^T \underline{x}_i \} \end{aligned}$$

• نتیجه داده:

identical distribution } iid
independant

$$\begin{aligned} \bar{d}_x^2 &= 2 E \{ \underline{x}^T \underline{x} \} - 2 E \{ \underline{x}^T \} E \{ \underline{x} \} \\ &= 2 \text{tr} [E \{ \underline{x} \underline{x}^T \} - m m^T] \\ &= 2 \text{tr} [[R] - m m^T] \\ &= 2 \text{tr} [\Sigma]_x \end{aligned}$$

Subject:

Year:

Month:

Date:

70

$$y = [\phi]^T x$$

$$[\phi] = [\phi_1 \ \phi_2 \ \dots \ \phi_m]$$

$$[\phi]^T [\phi] = [I] \quad \longrightarrow \text{orthonormal transformation}$$

$$\bar{d}_y^2 = 2 \operatorname{tr} [\Sigma]_y \quad \longleftarrow \text{distance preserved}$$

$$\bar{d}_y^2 = 2 \operatorname{tr} [\Sigma]_y$$

$$= 2 \operatorname{tr} ([\phi]^T [\Sigma]_x [\phi])$$

$$= 2 \sum_{i=1}^m \phi_i^T [\Sigma]_x \phi_i$$

Representation of

maximize \bar{d}_y^2

$$\text{subject to } \phi_i \cdot \phi_j = \begin{cases} 1 & , i=j \\ 0 & , i \neq j \end{cases}$$

$$\bar{E}^2 = \sum_{i=1}^m \phi_i^T [\Sigma]_x \phi_i$$

minimize \bar{E}^2 (minimize)

$$\bar{d}^2 = 2 \sum_{i=1}^m \phi_i^T [\Sigma]_x \phi_i$$

maximize \bar{d}^2 (maximize)

best representation!

نمایش داده‌ای حاضر در برابر شده است

۹: ۱۵:۱۵

Computer Project: 1, 2

Problems: 1, 2, 3

تعمیر در سطح تحقیقاتی: عنوان پروژه + مراجع + بررسی ای

Pattern Recognition - Pattern Recognition Letter

Intl. J. of PR - IEEE PAMI

PAPCO

تحلیل پروژه: ۳ هفته از آخرین امتحان گذشته

Subject :

Year :

Month :

Date :

()

• آب شخصی وید (population entropy)
شخصی برای اندازه گیری عدم قطعیت در داده ها.

$$h_x = - E \{ \ln P_x(x) \}$$

• برای بازگامی داده ها، مدب پیشینه آموزش عدم قطعیت داده است (classification) بر خلاف (classification) و البته به نایب توزیع است.

$$P_x(x) = N(m_x, [\Sigma]_x)$$

$$h_x = - E \left\{ \frac{1}{2} (x - m_x)^T [\Sigma]_x^{-1} (x - m_x) + \frac{1}{2} \ln |[\Sigma]_x| + \frac{n}{2} \ln(2\pi) \right\}$$

$$= \frac{1}{2} E \left\{ \text{tr}([\Sigma]_x^{-1} (x - m_x)(x - m_x)^T) \right\} + \dots$$

$$= \frac{1}{2} E \left\{ \text{tr}([\Sigma]_x^{-1} [\Sigma]_x) \right\} + \dots$$

$$= \frac{n}{2} + \frac{1}{2} \ln |[\Sigma]_x| + \frac{n}{2} \ln(2\pi)$$

$$h_y = \frac{m}{2} + \frac{1}{2} \ln |[\Sigma]_x| + \frac{m}{2} \ln(2\pi)$$

$$= \frac{m}{2} + \frac{1}{2} \ln |[\Phi]_m^T [\Sigma]_x [\Phi]_m| + \frac{m}{2} \ln(2\pi)$$

این رابطه باید پیشینه شده و ترجمه به محردیت orthogonal trans. :


$$\Sigma_y = [\Phi]_m^T \Sigma_x [\Phi]_m = [\lambda] \rightarrow \ln \Sigma_y = \ln |[\lambda]| = \sum \ln(\lambda_i)$$

برای بیشینه شدن آن نردلترین تناظر آینه استاده می کنیم
 eigen value و انتخاب کرده راز eigen vector

Feature Extraction & Linear Mapping 4 Classification (۱۵ فصل)

Class Seperability

این شاخص مد نظر است.
 به تدریج دلالت است و به نوع classifier استاده شده نیز بستگی دارد.



برای همیشه عدد بیک بعد، آن بعد استادی بیشترین تغییرات انتخاب می شود. این انتخاب برای representation است.
 برای داشتن کمترین خطا برای classification، استادی ϕ_2 مناسبتر است.

نقطه: بردارون linear transformation مناسب به طوری که seperable بودن را حفظ کند.

$$\underline{y} = [a]^T \underline{x}$$

\downarrow
 $m \times 1 \quad n \times m \quad n \times 1$

Bayes Classifier

$$p_i(x) \quad i = 1, \dots, M$$


$$g_i = q_i(x)$$

Subject :

Year. Month. Date. ()

$$q_k(x) = \sum_{j=1}^M \omega_j q_{kj}(x) \rightarrow y_i \geq y_j$$

$$\sum_{i=1}^M q_k(x) = 1$$



M-1 تابع مستقل محدود دارد.

• دو نوع تابع معیار در این مدل استفاده می شود.

1. Based on family of scatter matrices
2. Based on bounds

Scatter Matrices

* Within-Class Scatter Matrix

$$[S]_w = \sum_{i=1}^M P_i \cdot E \{ (x - m_i)(x - m_i)^T \mid \omega_i \}$$

$$= \sum_{i=1}^M P_i \cdot [\Sigma]_i$$

ماتریس پراکندگی درون کلاسی = میانگین ماتریسهای پراکندگی درون کلاسی

* Between-Class Scatter Matrix

$$[S]_b = \sum_{i=1}^M P_i (m_i - m_0)(m_i - m_0)^T$$

Subject:

Year. Month. Date. 72


$$m_i = E \{X | w_i\}$$

$$m_0 = \sum_{i=1}^M p_i m_i = E \{X\}$$

* Mixture scatter matrix

$$[S]_m = E \{(\underline{X} - m_0)(\underline{X} - m_0)^T\}$$

$$= [S]_w + [S]_b$$



* General Form of Scatter Criteria:

$$\textcircled{a} J_1 = \text{tr}([S]_2^{-1} [S]_1)$$

$$[S]_2 = [S]_w$$

✓

$$[S]_1 = [S]_b$$

$J_1 \uparrow \Rightarrow \text{seperability} \uparrow$

✓

$$[S]_2 = [S]_m$$

$$[S]_1 = [S]_w$$

$J_1 \uparrow \Rightarrow \text{seperability} \downarrow$

$$\textcircled{a} J_2 = \ln | [S]_2^{-1} [S]_1 | = \ln | [S]_1 | - \ln | [S]_2 |$$

, $[S]_2 \neq [S]_b \rightarrow$ جن طقس زارد

$$\textcircled{a} J_3 = \text{tr} [S]_1 - \mu (\text{tr} [S]_2 - c)$$

Subject:

Year:

Month:

Date:

()

$$\textcircled{c} J_4 = \frac{\text{tr} [S]_1}{\text{tr} [S]_2}$$

Optimum Linear Transform.

$$\underline{Y} = [a]^T \underline{X}$$

there is no constraint on $[a]$ to be orthonormal ($[a]^T [a] \neq [I]$)

$$[\Sigma]_Y = [a]^T [\Sigma]_X [a]$$

$$[S]_Y = [a]^T [S]_X [a] \quad \rightsquigarrow \text{scatter matrix}$$

$$J_1(m) = \text{tr} ([S]_{2Y}^{-1} [S]_{1Y})$$

$$= \text{tr} \{ ([a]^T [S]_{2X} [a])^{-1} ([a]^T [S]_{1X} [a]) \}$$

$$\frac{dJ_1}{d[a]} = 0 \quad \rightarrow \text{Appendix A - A.16}$$

$$\frac{\partial J_2(m)}{\partial [a]} = -2 \underline{S}_{2X} A \underline{S}_{2Y}^{-1} \underline{S}_{1Y} \underline{S}_{2Y}^{-1} + 2 \underline{S}_{1X} A \underline{S}_{2Y}^{-1} = 0$$

$$\Rightarrow \underline{S}_{1X} A \underline{S}_{2Y}^{-1} = \underline{S}_{2X} A \underline{S}_{2Y}^{-1} \underline{S}_{1Y} \underline{S}_{2Y}^{-1}$$

$$\Rightarrow \underline{S}_{2X}^{-1} \underline{S}_{1X} A \underline{S}_{2Y}^{-1} = A \underline{S}_{2Y}^{-1} \underline{S}_{1Y} \underline{S}_{2Y}^{-1}$$

$$\Rightarrow (\underline{S}_{2X}^{-1} \underline{S}_{1X}) A = A (\underline{S}_{2Y}^{-1} \underline{S}_{1Y})$$

$$\underline{Y} = A^T \underline{X}$$

$$\underline{Z} = B^T \underline{Y}$$

linear transformation

$$B^T \underline{S}_{1Y} B = [A]_m \quad \text{coeff}$$

$$B^T \underline{S}_{2Y} B = [I]_m$$

Subject:

Year: Month: Date: 73

در واقع S_{2y} و S_{1y} را به طریقی تغییر می‌دهیم

$$\begin{aligned} \text{tr} (S_{2x}^{-1} S_{1x}) &= \text{tr} ((B^T S_{2y} B)^{-1} (B^T S_{1y} B)) \\ &= \text{tr} (B^{-1} S_{2y} B^{-T} B^T S_{1y} B) \\ &= \text{tr} (S_{2y}^{-1} S_{1y} B B^{-1}) \\ &= \text{tr} (S_{2y}^{-1} S_{1y}) \end{aligned}$$

این تبدیلی، مقدار criteria تغییر نمی‌کند.

$$B^T S_{1y} B = [M] \Rightarrow$$

$$B^T S_{1y} = [M] B^{-1} \Rightarrow$$

$$S_{1y} = B^{-T} [M] B^{-1}$$

$$B^T S_{2y} B = [I] \Rightarrow$$

$$B^T S_{2y} = B^{-1} \Rightarrow$$

$$S_{2y} = B^{-T} B^{-1}$$

با جایگزینی

$$S_{2y}^{-1} S_{1y} = (B^{-T} B^{-1})^{-1} (B^{-T} [M] B^{-1})$$

$$= (B B^T) (B^{-T} [M] B^{-1})$$

$$= B [M] B^{-1}$$

پس

$$(S_{2x}^{-1} S_{1x}) A = A (S_{2y}^{-1} S_{1y}) \Rightarrow$$

$$(S_{2x}^{-1} S_{1x}) A = A (B [M] B^{-1}) \Rightarrow$$

$$(S_{2x}^{-1} S_{1x}) AB = AB ([M])$$

AB دارای مقادیر λ - Z می‌باشد.

[M] نیز eigen value است پس $(S_{2y}^{-1} S_{1y})$ نیز eigen value است پس $(S_{2x}^{-1} S_{1x})$ نیز eigen value است.

Subject:

Year:

Month:

Date:

()

برای محاسبه به جداول نظری کردن میزنند ، تعداد دایره ها در [M] اعداد حقیقی مثبت هستند

$$J(n) = \text{tr} (S_{2 \times 2}^{-1} \cdot 1 \times 1) = \lambda_1 + \dots + \lambda_n$$

$$J(m) = \text{tr} (S_{2 \times 2}^{-1} \cdot 1 \times 1) = \mu_1 + \dots + \mu_m$$

برای مینه و ماکزیمم کردن J به ترتیب بزرگترین و کوچکترین مقدارهای دایره استفاده می شود

2-class

$$J_T = \text{tr} ([S]_w^{-1} [S]_b) \quad \begin{matrix} \rightarrow S_2 = [S]_w \\ \rightarrow S_1 = [S]_b \end{matrix}$$

داده ها کم شود $\Rightarrow [S]_w \downarrow \Rightarrow [S]_w^{-1} \uparrow$
داده ها زیاد شود $\Rightarrow [S]_b \uparrow$ $\rightarrow J \sim \text{maximize}$

$$Y = [A]^T X$$

$$\begin{aligned} [S]_b &= \sum_{i=1}^M P_i (m_i - m_0) (m_i - m_0)^T && \begin{matrix} P_i = \text{احتمال اولیه } i \text{ ظاهر} \\ m_0 = P_1 m_1 + P_2 m_2 \end{matrix} \\ &= P_1 (m_1 - m_0) (m_1 - m_0)^T + P_2 (m_2 - m_0) (m_2 - m_0)^T \\ &= P_1 (m_1 - (-)) (m_1 - (-))^T + P_2 (m_2 - (-)) (m_2 - (-))^T \\ &= \dots \\ &= [P_1 P_2^2 + P_1^2 P_2] (m_2 - m_1) (m_2 - m_1)^T \\ &= P_1 P_2 (P_1 + P_2) (m_2 - m_1) (m_2 + m_1)^T \\ &= P_1 P_2 (m_2 - m_1) (m_2 - m_1)^T \end{aligned}$$

تفاوت شرط مستقل در جدول نیست می آید من:

$$\text{Rank} ([S]_b) = 1$$

$$\text{Rank} ([S]_w^{-1}) = \text{full rank}$$

$$\text{Rank} ([S]_w^{-1} [S]_b) = 1 \quad \sim \text{این شرط}$$

Subject:

Year: _____

Month: _____

Date: _____ 74

* پس نهایتاً سطر استیل درود:

$$\text{tr}(S_w^{-1} S_b) = \lambda_1$$

$$\lambda_1 = \text{eigen value}(S_w^{-1} S_b) \neq 0$$

$$= \text{tr}(S_w^{-1} (P_1 P_2 (m_2 - m_1)(m_2 - m_1)^T))$$

$$= P_1 P_2 (\text{tr}((m_2 - m_1)^T S_w^{-1} (m_2 - m_1)))$$

$$= P_1 P_2 ((m_2 - m_1)^T S_w^{-1} (m_2 - m_1))$$

$$\underline{\phi}_1 = \frac{[S]_w^{-1} (m_2 - m_1)}{\| [S]_w^{-1} (m_2 - m_1) \|}$$

$$(S_w^{-1} S_b) \underline{\phi}_1 = \lambda_1 \underline{\phi}_1$$

* پس اگر نیاز به تبدیل باشد:

$$\underline{y} = [a]^T \underline{x}$$

$$[a] = \underline{\phi}_1$$

$$\underline{y} = \underline{\phi}_1^T \underline{x} = \text{cte}$$

همان دو بعد به یک بعد:

$$\underline{y} = c [[S]_w^{-1} (m_2 - m_1)]^T \underline{x}$$

تبدیل

$$\underline{y} = c (m_2 - m_1)^T [S]_w^{-1} \underline{x}$$

Bayes Classifier

* نتایج

$$q_i(x) \quad i = 1, \dots, M$$

$$q_i = \sum_{j=1}^M q_j$$

$$q_1 + \dots + q_M = 1$$

در اینجا کلاسها را با یکدیگر مقایسه می‌کنیم.

Subject:

Year. Month. Date. ()

Linear classification

$$h(x) = v^T x$$

$$v = (S \Sigma_1 + (1-s) \Sigma_2)^{-1} (m_2 - m_1)$$

کمی [S] بر این می دهد → یعنی براندگی Σ در این می دهد

M - class


$$[S]_b = \sum_{i=1}^M P_i (m_i - m_0)(m_i - m_0)^T$$

$$J = \text{tr}([S]^{-1} [S]_b)$$

$$\text{Rank}([S]_b) = M - 1$$

$$\text{Rank}(J) = M - 1 \rightarrow \lambda_1, \dots, \lambda_{M-1} \neq 0 \rightarrow \phi_1, \dots, \phi_{M-1}$$

حالت خاص



$$m_0 = m_1 = m_2$$

این ساختن خوب عمل نمی کند. چون براندگی حول میانیس را نشان می دهد.

$$S_2 = S_m$$

$$S_1 = S_w$$

$$J = \text{tr}(S_m^{-1} S_w)$$

Subject:

Year: Month: Date: 75

$$(S_{yx}^{-1} S_{yx}) AB = AB ([\mu]) \Rightarrow$$

$$(S_m^{-1} S_w) [\phi] = [\phi] [\lambda] \Rightarrow$$

$$\begin{cases} \text{eigen value matrix } S_m^{-1} S_w = [\lambda] \\ \text{eigen vector matrix } S_m^{-1} S_w = [\phi] \end{cases}$$

$$\begin{cases} S_w [\phi] = S_m [\phi] [\lambda] \Rightarrow \\ S_m = S_w + S_b \end{cases}$$

$$S_w [\phi] = (S_w + S_b) [\phi] [\lambda] \Rightarrow$$

$$S_b [\phi] [\lambda] = S_w [\phi] ([\lambda] - [I]) \Rightarrow$$

$$S_w^{-1} S_b [\phi] [\lambda] = [\phi] ([\lambda] - [I]) \Rightarrow$$

$$S_w^{-1} S_b [\phi] = [\phi] ([\lambda]^{-1} - [I])$$

الرتباً زیر و بیشتره $S_m^{-1} S_w$ و مرتب کنیم

$$\lambda_1 > \lambda_2 > \lambda_3 > \dots > \lambda_n$$

حل بتایر بیشتره $S_w^{-1} S_b$ و مرتب می کنیم

$$\left(\frac{1}{\lambda_1} - 1\right) < \left(\frac{1}{\lambda_2} - 1\right) < \dots < \left(\frac{1}{\lambda_n} - 1\right)$$

Optimization of $J_2(m)$ *

$$J_2(m) = \ln |S_{yx}| - \ln |S_{xy}|$$

$$\underline{y} = [A]^T \underline{x}$$

$$J_2(m) = \ln |A^T S_{yx} A| - \ln |A^T S_{2x} A|$$

$$\frac{\partial J_2(m)}{\partial A} = [\phi] \rightarrow \text{Appendix A, A.28}$$

Subject:

Year:

Month:

Date:

()

$$\frac{\partial J}{\partial A} = 2 \{ S_{1x} A S_{1y}^{-1} - S_{2x} A S_{2y}^{-1} \} = 0$$

$$S_{1x} A S_{1y}^{-1} = S_{2x} A S_{2y}^{-1}$$

$$S_{2x}^{-1} S_{1x} A S_{1y} S_{1y}^{-1} = S_{2x}^{-1} S_{2x} A S_{2y}^{-1} S_{1y}$$

$$(S_{2x}^{-1} S_{1x}) A = A (S_{2y}^{-1} S_{1y})$$

مشابه J_1 است

$$J_2(m) = \ln \frac{|S_{1y}|}{|S_{2y}|} = \ln |S_{2y}^{-1} S_{1y}|$$

$$= \ln \lambda_1 + \dots + \ln \lambda_m$$

تفاوت آن! J_1 نسبت به S_{2y} معیار هر دو باشد.

Rank (S_b) \neq full rank

$$|S_b| = 0$$

$$S_2 \neq |S_b|$$

بس

موضوع داده واقعی

<http://kdd.ics.uci.edu>

موضوعات گسسته

1. Combination of Classifier
2. Non-linear Classifier
3. Clustering
4. SVMs
5. Density Estimation

Subject: _____

Year: _____ Month: _____


Date: 76

6. Application

7. Validation

8. Feature Selection & Extraction

9. Micro-array Data Processing

Validation 

چگونه؟ *

• وجود پارامترهای آزاد

KNN \rightarrow k

Parzen \rightarrow h

Feature Reduction \rightarrow m

• نکات مهم:

انتخاب مدل

خطای سفت مقدار واقعی

• تعداد داده محدود

استاندارد برای آموزش

استاندارد از زمان داده برای Test

generalization

خطای کمزور مقدار واقعی (خراب بینانه)

Naive

• روشهای دیگر

• روشهای مناسب برای همین عملکرد

test + training

hold out

اطلاعات داده؟
چگونه است؟
مدل است

Resampling

اصلاح روشهای

Subject:

Year:

Month:

Date:

()

Random Sub Sampling

- تعدادی داده به طور تصادفی از اردن داده برداشته می شود برای test استفاده می شود.
- این کار k بار صورت می گیرد.
- خطای حاصل از این k بار را میانگین می گیریم.
- برداشتن داده بدون جایگزینی است.


k - Fold Cross Validation

- کل داده به k قسمت تقسیم می شود.
- به نوبت بخش را برای test نگه می داریم.
- خطای حاصل از این k بار را میانگین می گیریم.

Leave One Out

- یک داده نگه داشته می شود برای Test
- بقیه $n-1$ داده مانده، طراحی انجام می شود، به این دلیل که خارج مانده است test می شود.
- به نوبت n نمونه ایط انجام می شود.
- خطای حاصل میانگین گرفته می شود.

چند Fold ?



$\checkmark k=3$ ← Large Datasets

$k=N$ ← \checkmark Leave One Out ← Small Datasets

$k=10$ ← Normal

Subject:

Year: .. Month: ..

Date: .. 77

Bootstrap

Random Sub Sampling

با تکرار زیاد
داده‌های آزمون چند بار در داده‌های آموزش استفاده شده
داده‌های استفاده نشده در آزمون استفاده می‌شود

در این ↑

Three Way Data Estimate

داده
Training Set
validation Set
Test Set

تولید پارامترهای classifier

Subject:

Year:

Month:

Date:

()

Clustering



• مب :

روش مدین نظر

رسنه بندي داده در بر حسب وزن به آنها بودن حساسه نظر

• sensible

• مراحل طی

1. Feature selection
2. Proximity Measure
 - Similarity
 - Dissimilarity
3. Clustering Criterion
 - Compact Cluster
 - Elongated Cluster
4. Clustering Alg.
5. Validation → Expert
6. Interpret
7. Tendency

• انواع دژنهها

- ← درزادی — Nominal —
- ← ترتیبی — Ordinal —
- Time Scale —
- ... —

• انواع الگوریتم

- Sequential —
- (Bottom-up) Agglomerative
 - (Top-Down) Divisive
- ← Hierarchical —

Subject :

Year :

Month :

Date :

78

Fitness Functions -

Ad-Hoc -

• خوشه بندی سلسله مراتبی : روش تجزیه

• Agglomerative Clustering Alg

• هر Cluster یک نمونه آغازی است - خوشه در ترتیب می شوند - در پایان سطح یک خوشه ماند

• Bottom-Up روش

• الگوریتم طی

1. Begin with N cluster
each sample $\in C$

2. Repeat step 3 a total of $N-1$ times

3. Find the most similar clusters C_i & C_j
merge C_i & C_j into one cluster

• روش (SL) Single-linkage

Min Method


Nearest Neighbor Method

$$D_{SL}(C_i, C_j) = \min d(a, b)$$

$a \in C_i$

$b \in C_j$


$d(a, b) \equiv$ distance between the
samples a, b



Subject:

Year. Month. Date. ()

sample #	(x, y)
1	(4, 4)
2	(8, 4)
3	(15, 8)
4	(24, 4)
5	(24, 12)




شکل ماتریس شباهت نمونه‌ها

Similarity Matrix (دک)

	1	2	3	4	5
1	-	4	11.7	20	21.5
2		-	8.1	16	17.9
3			-	9.8	9.8
4				-	8
5					-

distance



- level 1 : {1} {2} {3} {4} {5}
- level 2 : {1,2} {3} {4} {5}
- level 3 : {1,2} {3} {4,5}
- level 4 : {{1,2}, 3} {4,5}
- level 5 : {{{1,2}, 3}, {4,5}}

دندروگرام Dendrogram — ماتریسهای شباهت با بردن اطلاعات این یعنی در نتیجه آنها در دسترس آورد.

این روش compact cluster بوجود می‌آورد.

* روش
 (Ch) Complete Linkage
 Maximum Method
 Farthest Neighbor Method

Subject:

Year: _ Month: _ Date: 79

$$D_{cl}(C_i, C_j) = \max_{a \in C_i, b \in C_j} d(a, b)$$


$a \in C_i$

$b \in C_j$

برای دوستان، بهترین فاصله استاندارد می شود این D تنها فاصله بین خوشه است.

Similarity Matrix \Rightarrow

	{1,2}	3	4	5		{1,2}	3	{4,5}
{1,2}	0	11.7	20	21.5	{1,2} <td>0</td> <td>11.7</td> <td>21.5</td>	0	11.7	21.5
3		0	9.8	9.8	3 <td></td> <td>0</td> <td>9.8</td>		0	9.8
4			0	8.0	{4,5} <td></td> <td></td> <td>0</td>			0
5				0				



Unweighted Pair-Group method Using Arithmetic Average (UPGMA) روش

برای تعیین بودن حساسیت بر روی روشهای تکی به نسبت حساس بود

$$D(C_i, C_j) = \frac{1}{n_i \times n_j} \sum_{a \in C_i, b \in C_j} d(a, b)$$


$a \in C_i$

$b \in C_j$

$C_i = i^{th}$ cluster with n_i members

Subject:

Year. Month. Date. ()



$$D(C_1, C_2) = \frac{1}{2 \times 1} (d(1,5) + d(2,3)) = 9.9$$

$$D(C_{12}, C_{45}) = \frac{1}{2 \times 2} (d(\{1,2\}, 4) + d(\{1,2\}, 5)) = 8.9$$

Ward's Method

Min Variance Method

رژش *

C_1, C_2, \dots, C_N \sim initial clusters

smallest square error

$\underline{x}^1, \dots, \underline{x}^N$

$$E = \sum_{i=1}^N \sum_{j=1}^n (x_j^i - \mu_j)^2$$

$$\underline{x}^{(i)} = \begin{bmatrix} x_1^{(i)} \\ \vdots \\ x_n^{(i)} \end{bmatrix}$$

$$E = N \sigma^2 = N (\sigma_1^2 + \dots + \sigma_k^2)$$

د

clusters	squared error
{1,2}, {3}, {4}, {5}	$\mu = \frac{1}{2} \left[\binom{4}{4} + \binom{6}{4} \right] = \binom{6}{4} \rightarrow E_{1,2} = (4-6)^2 + (6-6)^2 + (4-4)^2 + (4-4)^2 = 8$ $E = 8 + 0 + 0 + 0 = \underline{8} \checkmark$
{1,3}, {2}, {4}, {5}	68.5
{1,4}, {2}, {3}, {5}	200
{1,5}, {2}, {3}, {4}	232
{1}, {2,3}, {4}, {5}	32
{1,2}, {3}, {4,5}	40 \checkmark

خوشه‌ها بر اساس اطلاعات پراکنده شدن می‌شوند

Subject:

Year:

Month:

Date:

80

گروه آموزشی سلسله مراتبی : روشهای تقسیم کننده

* روش Forgy *

input: $K = \#$ of clusters

$k \times seed$

1. initialize the cluster centroid (seed points)
2. each sample
Find the closest cluster (based on their centroids)
assign sample to its cluster
3. if no samples changed clusters in step 2 \rightarrow stop
4. compute the centroids of resulting clusters & goto 2

$K = 2$

seeds: $(4, 4)$, $(8, 4)$

	$(4, 4)$	$(8, 4)$	$(15, 8)$	$(24, 4)$	$(24, 12)$
Nearest centroid	$(4, 4)$	$(8, 4)$	$(8, 4)$	$(8, 4)$	$(8, 4)$
	$\{(4, 4)\}$	$\{(8, 4), (15, 8), (24, 4), (24, 12)\}$			

seeds: $(4, 4)$, $(17.75, 7)$

	$(4, 4)$	$(4, 4)$	$(17.75, 7)$	$(17.75, 7)$	$(17.75, 7)$
	$\{(4, 4), (8, 4)\}$	$\{(15, 8), (24, 4), (24, 12)\}$			

seeds: $(6, 4)$, $(21, 8)$

	$(6, 4)$	$(6, 4)$	$(21, 8)$	$(21, 8)$	$(21, 8)$
	c_1	c_1	c_2	c_2	c_2

PAPCO

No Cluster Change \Rightarrow Stop

Subject:

Year:

Month:

Date:

()

k-means

ک-میانس

input : $k = \# \text{ of clusters}$, $k \text{ seeds}$

1. Begin with k cluster

each cluster consists of 1 sample

for remaining $(N-k)$ sample

find the closest clusters

after each sample is assigned

recompute the centroid

2. Go through data a second time

DO NOT update the centroids

$k=2$

✓

seeds: $(\begin{smallmatrix} 8 \\ 4 \end{smallmatrix})$, $(\begin{smallmatrix} 24 \\ 4 \end{smallmatrix})$

$\begin{matrix} \text{✓} \\ \text{✓} \end{matrix} \quad x = (\begin{smallmatrix} 15 \\ 8 \end{smallmatrix}) \rightarrow \begin{matrix} d(x, \bar{c}_1) \checkmark \\ d(x, \bar{c}_2) \end{matrix} \rightarrow c_1 \rightarrow \begin{cases} c_1: \{(\begin{smallmatrix} 8 \\ 4 \end{smallmatrix}), (\begin{smallmatrix} 15 \\ 8 \end{smallmatrix})\} \\ c_2: \{(\begin{smallmatrix} 24 \\ 4 \end{smallmatrix})\} \end{cases} \rightarrow \begin{matrix} \bar{c}_1 = (\begin{smallmatrix} 11.5 \\ 6 \end{smallmatrix}) \\ \bar{c}_2 = (\begin{smallmatrix} 24 \\ 4 \end{smallmatrix}) \end{matrix}$

$\text{✓} \quad x = (\begin{smallmatrix} 4 \\ 4 \end{smallmatrix}) \rightarrow \begin{matrix} d(x, \bar{c}_1) \checkmark \\ d(x, \bar{c}_2) \end{matrix} \rightarrow c_1 \rightarrow \begin{matrix} \bar{c}_1 = (\begin{smallmatrix} 9 \\ 5.3 \end{smallmatrix}) \\ \bar{c}_2 = (\begin{smallmatrix} 24 \\ 4 \end{smallmatrix}) \end{matrix}$

$\text{✓} \quad x = (\begin{smallmatrix} 24 \\ 12 \end{smallmatrix}) \rightarrow \begin{matrix} d(x, \bar{c}_1) \\ d(x, \bar{c}_2) \checkmark \end{matrix} \rightarrow c_2 \rightarrow \begin{matrix} \bar{c}_1 = (\begin{smallmatrix} 9 \\ 5.3 \end{smallmatrix}) \\ \bar{c}_2 = (\begin{smallmatrix} 24 \\ 8 \end{smallmatrix}) \end{matrix}$

حل بر سر کلمه (د) کا دیکھو ! $\bar{c}_2 = (\begin{smallmatrix} 24 \\ 8 \end{smallmatrix})$, $\bar{c}_1 = (\begin{smallmatrix} 9 \\ 5.3 \end{smallmatrix})$ نہ بقیہ ہی لکھو۔
 $c_1 = \{ (\begin{smallmatrix} 8 \\ 4 \end{smallmatrix}), (\begin{smallmatrix} 15 \\ 8 \end{smallmatrix}), (\begin{smallmatrix} 4 \\ 4 \end{smallmatrix}) \}$

✓ $c_2 = \{ (\begin{smallmatrix} 24 \\ 4 \end{smallmatrix}), (\begin{smallmatrix} 24 \\ 12 \end{smallmatrix}) \}$