

Zur Aufgabe 10.4

$U \subseteq \mathbb{R}^n$ k -dim. UVR, $x \in \mathbb{R}^n$ zufällig, $x_i \sim N(0, \frac{1}{n})$.

Was ist $E[\min_{u \in U} \|x - u\|^2]$, wenn $n \rightarrow \infty$?

$$\underline{\text{Beh.}}: E[\min_{u \in U} \|x - u\|^2] = \frac{n-k}{n} \xrightarrow{n \rightarrow \infty} 1.$$

Bew.: Sei u_1, \dots, u_k eine ONB von U und u_{k+1}, \dots, u_n eine ONB von U^\perp . Dann ist

$$\min_{u \in U} \|x - u\|^2 = \sum_{i=k+1}^n (u_i^T x)^2.$$

$$\text{Also: } E[\min_{u \in U} \|x - u\|^2] = \left(\frac{1}{\sqrt{\frac{2\pi}{n}}}\right)^n \int_{\mathbb{R}^n} \sum_{i=k+1}^n (u_i^T x)^2 \exp\left(-\frac{n}{2} \sum_{j=1}^k x_j^2\right) dx$$

[Variablentransformation: Ersetze x durch $A^{-1}x$,

$$\text{mit } A = \begin{bmatrix} u_1^T \\ \vdots \\ u_n^T \end{bmatrix} \in O(n).$$

$$= \left(\frac{1}{\sqrt{\frac{2\pi}{n}}}\right)^n \int_{\mathbb{R}^n} \sum_{i=k+1}^n x_i^2 \exp\left(-\frac{n}{2} \sum_{j=1}^k x_j^2\right)$$

$$= E\left[\sum_{i=k+1}^n x_i^2\right] = \frac{n-k}{n}.$$

Klassifikation:

$$X = \{x_1, \dots, x_M\}, Y = \{y_1, \dots, y_N\} \subseteq \mathbb{R}^n.$$

X und Y können durch eine affin-lineare Fkt.

$f(x) = \alpha^T x - \beta$ getrennt werden \Leftrightarrow

$$0 < t^* = \max t$$

$$\alpha^T x_i - \beta \geq t^*, i=1, \dots, M$$

$$\alpha^T y_i - \beta \leq -t^*, i=1, \dots, N$$

$$\|\alpha\| \leq 1$$

$$= \min_{\substack{x \in \text{conv } X, \\ y \in \text{conv } Y}} \frac{1}{2} \|x - y\|^2$$

$$x \in \text{conv } X,$$

$$y \in \text{conv } Y.$$

nicht

In realistischen Szenarien können X und Y mit einer affin-linearen Fkt. getrennt werden.

Dann werden sog. "support vector machine" (SVM) verwendet.

Ersetze in der Originalformulierung

$$\alpha^T x_i - \beta \geq 1$$

$$\alpha^T y_i - \beta \leq -1$$

durch

$$\alpha^T x_i - \beta \geq 1 - u_i$$

$$\alpha^T y_i - \beta \leq -(1 - v_i)$$

(*)

für $u_i \geq 0, v_i \geq 0$.

Falls $\mu = v = 0$, dann haben wir die Originalformulierung.

Falls μ, v genügend groß ist, können die Bed. (x) immer erfüllt werden.

Heuristik: Minimiere die l_1 -Norm des Vektors (μ, v)

Ergibt lineares Programm:

$$\min \sum_{i=1}^M u_i + \sum_{i=1}^N v_i$$

$$u_i \geq 0, i=1, \dots, M,$$

$$v_i \geq 0, i=1, \dots, N,$$

$$a^T x - \beta \geq 1 - u_i, i=1, \dots, M,$$

$$a^T x - \beta \leq -(1 - v_i), i=1, \dots, N.$$

Alternative: Minimiere l_1 -Norm von (μ, v) und gleichzeitig maximiere die Breite des Streifens $\{x : -1 \leq a^T x - \beta \leq 1\}$, der durch $\frac{2}{\|a\|_1}$ gegeben ist.

Für $S > 0$ löse das konvexe, quadratische Programm

$$\min \|a\|_1 + S \left(\sum_{i=1}^M u_i + \sum_{i=1}^N v_i \right)$$

$$a^T x_i - \beta \geq 1 - u_i$$

$$a^T y_i - \beta \leq -(1 - v_i)$$

$$u_i \geq 0, v_i \geq 0.$$

" l_1 -norm soft-margin SVM"

§ 2 Nicht-lineare Klassifikation

Idee: Verwende nicht-lineare Einbettung von

$X, Y \subseteq \mathbb{R}^n$ in m -dim. VR, $m \gg n$.

$$\varphi: \mathbb{R}^n \rightarrow \mathbb{R}^m, \text{ z. B. } \varphi(x_1, x_2) = (x_1^2, x_1 x_2, x_2^2, x_1, x_2)$$

$\mathbb{R}^2 \qquad \qquad \qquad \mathbb{R}^5$

Dann können nicht-lineare trennende Hyperflächen im \mathbb{R}^m durch lineare Hyperebenen im \mathbb{R}^m approximiert werden.

Problem: Falls m sehr groß ist, ist das L_1 -norm soft-margin SVM aufwendig zu lösen.

Lösung: Dualisiere und verwende den "Kernel trick".

Das Dual ist:

$$\max \sum_{i=1}^m \lambda_i + \sum_{i=1}^N \mu_i$$

$$\left\| \sum_{i=1}^m \lambda_i x_i - \sum_{i=1}^N \mu_i y_i \right\| \leq 1$$

$$\lambda_i \in [0, S], \quad i = 1, \dots, m$$

$$\mu_i \in [0, S], \quad i = 1, \dots, N,$$

$$\sum_{i=1}^m \lambda_i = \sum_{i=1}^N \mu_i$$

Wenn man die Einbettung $\varphi: \mathbb{R}^n \rightarrow \mathbb{R}^m$ verwendet,
muß man die Bedingung

$$\left\| \sum_{i=1}^n \lambda_i \varphi(x_i) - \sum_{i=1}^N \mu_i \varphi(y_i) \right\|^2 \leq 1$$

in den Griff bekommen.

Der "Kernel-Trick": Diese Bedingung hängt nur von der Gram-Matrix $K: (X \cup Y) \times (X \cup Y) \rightarrow \mathbb{R}$ ab:

$$K(x_i, y_j) = \varphi(x_i)^T \varphi(y_j)$$

Falls man K effizient berechnen kann, dann ist die Dim. m der Einbettung irrelevant.

Die Fkt., die die Gram-Matrix beschreibt heißt Kern.

Beliebte Kerne sind (Wahl ist extrem anwendungsabh.)

(a) $K(x_i, x_j) = x_i^T x_j$ linear

(b) $K(x_i, x_j) = (x_i^T x_j)^d$ d-te Potenz

(c) $K(x_i, x_j) = \exp(-\frac{1}{2} \|x_i - x_j\|^2 / \sigma^2)$

radiale Basisfkt (oft verwendet)