

Übungsblatt 2

Ausgabe: 01.05.2017
 Abgabe: 08.05.2017

Aufgabe 2.1 *Agnostisches Lernen: Lineare Regression* (12 Punkte)

Sei $X = [0, 1]$ und $Y = \mathbb{R}$. Wir betrachten die Hypothesenklasse \mathcal{H} aller affinen Funktionen $f : X \rightarrow Y$ mit $f(x) = a \cdot x + b$, wobei $a, b \in \mathbb{R}$.

Sei $f \in \mathcal{H}$ mit $f(x) = a \cdot x + b$ im Folgenden fest. Wir wollen f anhand von Beispielen lernen. Die Beispiele sind aber durch einen additiven Fehler ξ verrauscht, wobei ξ normalverteilt um den Mittelwert $\mu = 0$ mit Varianz $\sigma^2 > 0$ sei. Der Lernalgorithmus erhält nur die verrauschten Beispiele (x, y) mit $y = f(x) + \xi$.

Die Verteilung D über $X \times Y$ sieht folgendermaßen aus: $D(x)$ ist die Gleichverteilung auf X und für ein gegebenes $x \in X$ ist $D(y|x)$ normalverteilt um den Mittelwert $\mu = f(x)$ mit Varianz σ^2 . Als Loss-Funktion wählen wir den quadratischen Loss.

- a) Sei die Beispielmenge $S = \{(x_1, y_1), \dots, (x_s, y_s)\}$ gegeben und ferner seien $x = (x_1, \dots, x_s)$, $y = (y_1, \dots, y_s)$ und $\bar{x} = \frac{1}{s} \sum_{i=1}^s x_i$ sowie $\bar{y} = \frac{1}{s} \sum_{i=1}^s y_i$.

Zeigen Sie, dass die Hypothese h_S mit

$$h_S(x) = \hat{a} \cdot x + \hat{b} \quad \text{mit} \quad \hat{a} = \frac{\text{Cov}[x, y]}{\text{Var}[x]} \quad \text{und} \quad \hat{b} = \bar{y} - \hat{a} \cdot \bar{x}$$

eine ERM-Hypothese ist. Dabei ist $\text{Cov}[x, y] = \frac{1}{s} \sum_i (x_i - \bar{x})(y_i - \bar{y})$ die (empirische) Kovarianz und $\text{Var}[x] = \frac{1}{s} \sum_i (x_i - \bar{x})^2$ die (empirische) Varianz.

Hinweis: $\text{Loss}^S(h_S)$ ist eine reellwertige Funktion, die von zwei reellen Parametern abhängt, also $\text{Loss}^S(h_S) : \mathbb{R}^2 \rightarrow \mathbb{R}$. Wie minimiert man eine solche Funktion?

- b) Berechnen Sie den Approximationsfehler von \mathcal{H} . Zeigen Sie dann, dass für eine gegebene Hypothese $h \in \mathcal{H}$ mit $h(x) = a' \cdot x + b'$ der Schätzfehler

$$\frac{1}{3}(a' - a)^2 + (a' - a)(b' - b) + (b' - b)^2$$

beträgt.

Bitte wenden!

Aufgabe 2.2 *Agnostisches PAC-Lernen: Wie viele Beispiele sind notwendig?* (10 Punkte)

In der Vorlesung wurde (für endliche Konzeptklassen und beschränkte Loss-Funktionen) eine obere Schranke für die hinreichende Beispielmengenzahl s für agnostisches PAC-Lernen gezeigt. Wir wollen nun eine *untere* Schranke für die *notwendige* Anzahl an Beispielen herleiten. Betrachte dazu ein Minimalbeispiel¹:

Gegeben seien die Mengen $X = \{x\}$, $Y = \{0, 1\}$ und die Hypothesenklasse $\mathcal{H} = \{(x, 0), (x, 1)\} \subseteq X \times Y$. Seien $0 < \varepsilon \leq \sqrt{1/2}$ und $0 < \delta \leq \frac{1}{4}$ fest. Die Verteilung sei D mit $\text{prob}_D[(x, 0)] = \frac{1+\varepsilon}{2}$ und $\text{prob}_D[(x, 1)] = \frac{1-\varepsilon}{2}$. Als Loss-Funktion wählen wir den 0-1-Loss.

Zu lernen ist also das „gute“ Konzept $c = (x, 0)$ mit dem geringstem erwartetem Loss.

- Sei $h = (x, 1)$ das „schlechte“ Konzept. Berechnen Sie den Approximationsfehler von \mathcal{H} sowie den Schätzfehler von h .
- Ein Lernalgorithmus erhalte eine gemäß D zufällig gezogene Beispielmengenzahl s der Größe $s < \frac{\ln(1/4\delta)}{2\varepsilon^2}$ und berechne eine ERM-Hypothese h_S .

Zeigen Sie: $\text{prob}[h_S = (x, 1)] > \delta$.

Hinweis: Sie dürfen folgende Ungleichungen ohne Beweis benutzen:

- Slud's Ungleichung:* Sei Z binomialverteilt² zu den Parametern n und $p = \frac{1-\varepsilon}{2}$. Dann gilt $\text{prob}[Z \geq n/2] \geq \frac{1}{2} \left(1 - \sqrt{1 - e^{-n\varepsilon^2/(1-\varepsilon^2)}}\right)$
- $\frac{1}{2}(1 - \sqrt{1-x}) \geq x/4$ für $x \in (0, 1]$.

Fazit: Die Beispielmengenzahl s reicht nicht aus, um mit hinreichender Wahrscheinlichkeit das richtige Konzept zu lernen.

Aufgabe 2.3 *VC-Dimension von Kugeln* (10 Punkte)

Für $d \in \mathbb{N}$, $m \in \mathbb{R}^d$ und $r > 0$ sei $K_r(m) := \{x \in \mathbb{R}^d : \|x - m\|^2 \leq r^2\}$ die d -dimensionale Kugel mit Radius r und Mittelpunkt m . Die Konzeptklasse $\text{KUGEL}_d = \{K_r(m) : m \in \mathbb{R}^d, r > 0\}$ besteht aus allen d -dimensionalen Kugeln.

- Zeigen Sie: $\text{VC}(\text{KUGEL}_2) = 3$.
- Zeigen Sie: Für beliebiges $d \in \mathbb{N}$ gilt $\text{VC}(\text{KUGEL}_d) \leq d + 1$.

Hinweis: Folgendes Ergebnis aus der Vorlesung könnte hilfreich sein: $\text{VC}(\text{HALBRAUM}_d) \leq d + 1$

¹Hier eine alltagstaugliche Interpretation: In einem Staat mit einem Zwei-Parteien-System (mit den Parteien 0 und 1) erhalte ein Demoskopie-Institut eine repräsentative Stichprobe der Größe s von Wahlzetteln, um daraus eine Hochrechnung zu erstellen, die vorhersagt, welche Partei die Mehrheit errungen hat. Liegen die (wahren) Ergebnisse der Parteien nah beieinander und ist die Stichprobe zu klein, so ist die Hochrechnung nicht zuverlässig.

²D.h. $\text{prob}[Z = k] = \binom{n}{k} p^k (1-p)^{n-k}$, vgl. <https://de.wikipedia.org/wiki/Binomialverteilung>