

Übungen zur Vorlesung
Theorie des Maschinellen Lernens
Sommer 2013
Übungsblatt 11

Aufgabe 11.1

Wir stellen ein eingeschränktes Modell für die reelle Regression auf:

Sei X eine Menge, $B \geq 1$ und F eine Menge von Funktionen von X nach $[-B, B]$. Sei $t \in F$ das Zielkonzept und P eine Verteilung über $X \times [-B, B]$, so dass für alle P -verteilten Tupel x, y gilt: $t(x) = y$. Den Fehler einer Hypothese $f \in F$ definieren wir so wie in der Vorlesung.

Gib einen sinnvollen Lerner L in diesem Modell an und beweise für endliche F eine obere Schranke für m_L .

Aufgabe 11.2

Verallgemeinere die obere Schranke für totalbeschränkte Klassen aus der Vorlesung auf Verteilungen mit einem beliegen $B \geq 1$. Jetzt erlauben wir also Verteilungen P über $X \times [1 - B, B]$. Zeige:

Sei F eine bezüglich der L_∞ -Metrik totalbeschränkte Klasse von Funktionen, die von X nach $[0, 1]$ abbilden, und sei \mathcal{A} ein approximativer SEM-Algorithmus für F . Dann ist L mit $L(z) := \mathcal{A}(z, \epsilon_0/12)$ und $\epsilon_0 := B^2 \cdot \sqrt{288/m}$ ein Lerner für F mit Stichprobengröße

$$m_L(\epsilon, \delta, B) \leq \frac{288 B^4}{\epsilon^2} \ln \left(\frac{2\mathcal{N}(\epsilon/(12B), F, d_{L_\infty})}{\delta} \right).$$

Gib nur die Änderungen zum Beweis aus der Vorlesung an.

Aufgabe 11.3

Zeige, dass die Voraussetzung *“die Funktionen in F sind beschränkt”* zum Lernen im Regressionsmodell notwendig ist. Es reicht, folgendes zu zeigen:

Es gibt ein F , das unbeschränkte Funktionen enthält, so dass man nicht mit einer polynomiellen Anzahl an Beispielen (polynomiell in $1/\epsilon$, $\log 1/\delta$ und $\log |F|$) lernen kann, selbst wenn $|F|$ endlich ist und wir nur Verteilungen P auf $X \times [0, 1]$ betrachten.

Aufgabe 11.4

Sei P eine Verteilung über $X \times \mathbb{R}$ und (x, y) sei P -verteilt. Zeige, dass der Minimierer von $\text{er}_P(f)$ genau $f(x) = E[y|x]$ ist.

Hinweis: Es reicht zu zeigen, dass

$$E[(f(x) - y)^2] = E[(f(x) - E[y|x])^2] + E[(y - E[y|x])^2] .$$

Beachte die Regeln des bedingten Erwartungswertes für Zufallsvariablen A, B, C :

- $E[A|B]$ ist eine Funktion in B
(insbesondere ist $E[A|B]$ selbst eine Zufallsvariable)
- Linearität: $E[\alpha \cdot A + \beta \cdot B|C] = \alpha \cdot E[A|C] + \beta \cdot E[B|C]$ mit $\alpha, \beta \in \mathbb{R}$
- Wenn A stochastisch unabhängig von B ist: $E[A|B] = E[A]$
- Satz der iterierten Erwartung: $E[E[A|B]] = E[A]$
- Wenn A eine Funktion in C ist (genauer: wenn A $\sigma(C)$ -messbar ist): $E[A|C] = A$
(zum Beispiel gilt $E[A|A] = A$; auch für Konstanten $\alpha \in \mathbb{R}$ folgt $E[\alpha|C] = \alpha$;
für Produkte gilt $E[A \cdot B|C] = A \cdot E[B|C]$)