

Algorithmische Grundlagen des Maschinellen Lernens
Sommersemester 2020
Übungsblatt 4

Aufgabe 1: (3 Punkte)

Es seien S und S' zwei Mengen von jeweils m Samples unabhängig gezogen aus der gleichen Verteilung. Zeigen Sie mittels geschickter Anwendung der Hoeffding-Ungleichung, dass für jede Hypothese h gilt

$$\Pr [|err_S(h) - err_{S'}(h)| \geq \gamma] \leq 2 \exp(-2m\gamma^2/4).$$

Aufgabe 2: (2 Punkte)

Zeigen Sie, dass eine Hypothesenklassen, die nicht im realisierbaren Sinn PAC-lernbar ist, auch nicht im agnostischen Sinn PAC-lernbar ist.

Aufgabe 3: (4 Punkte)

Angenommen, wir haben einen Lernalgorithmus, der den Trainingsfehler nur approximativ minimiert. Das heißt, für alle Trainingsmengen S gilt $err_S(h_S) \leq \min_{h \in \mathcal{H}} err_S(h) + \gamma$ für ein festes $\gamma > 0$.

Zeigen Sie, dass für jede Wahl von $\epsilon > 0$, $\delta > 0$, wenn S eine m -elementige Trainingsmenge aus einer Datenpunkt-/Label-Verteilung \mathcal{D} gezogen ist mit

$$m \geq \frac{8}{\epsilon^2} \ln \left(\frac{4\Pi_{\mathcal{H}}(2m)}{\delta} \right) .$$

dann gilt $err_{\mathcal{D}}(h_S) \leq \min_{h' \in \mathcal{H}} err_{\mathcal{D}}(h') + \epsilon + \gamma$ mit Wahrscheinlichkeit mindestens $1 - \delta$.

Aufgabe 4: (4+5 Punkte)

Bestimmen Sie die jeweils die VC-dimension der folgenden Mengensysteme. Beweisen Sie, dass Ihre Antwort richtig ist.

- (a) \mathcal{R} besteht aus Halbräumen der Form $r = \{ x \in \mathbb{R}^d \mid \langle a, x \rangle \geq 1 \}$ und Halbräumen der Form $r = \{ x \in \mathbb{R}^d \mid \langle a, x \rangle \leq 1 \}$.
- (b) \mathcal{R} besteht aus Halbräumen der Form $r = \{ x \in \mathbb{R}^d \mid \langle a, x \rangle \geq 0 \}$.

Tipp: Nutzen Sie aus, dass $d + 1$ Vektoren im \mathbb{R}^d immer linear abhängig sind.

Aufgabe 5: (2 Punkte)

Geben Sie ein Beispiel für einen Radonpunkt zweier disjunkter Teilmengen einer 5-elementigen Punktmenge im \mathbb{R}^3 . Ihr Beispiel sollte keine 4 Punkte enthalten, die affin abhängig sind.