

Übungen zur Vorlesung
Theorie des maschinellen Lernens
Sommer 18
Übungsblatt 06

Aufgabe 6.1 (4 Punkte)

Wir betrachten eine Variante des Perzeptron-Algorithmus. Wir ersetzen dazu den Aktualisierungsschritt $w^{(t+1)} = w^{(t)} + y_i x_i$ durch

$$w^{(t+1)} = w^{(t)} + \eta y_i x_i$$

für ein $\eta > 0$.

Zeige, dass diese Variante des Perzeptrons dieselbe obere Schranke für die Anzahl der Iterationen wie die Standardvariante hat.

Aufgabe 6.2 (4 Punkte)

Wir betrachten nun lineare Regression mit der Verlustfunktion $l(h, (x, y)) = |h(x) - y|$. Für eine Trainingsmenge $\{(x_i, y_i)\}_{i=1}^m$, wobei $x_i \in \mathbb{R}^d$ und $y_i \in \mathbb{R}$, soll gemäß der ERM-Regel das w gefunden werden, welches den Ausdruck

$$\sum_{i=1}^m |\langle w, x_i \rangle - y_i|$$

minimiert.

Zeige, dass sich obige Problemstellung in ein lineares Programm umwandeln lässt.

Aufgabe 6.3 (4 Punkte)

Sei $h_w : \mathbb{R}^3 \rightarrow [0, 1]$ mit $w \in \mathbb{R}^3$. Es gelte

$$h_{(w_1, w_2, w_3)}(x_1, x_2, x_3) := \frac{1}{1 + e^{-(w_1 x_1 + w_2 x_2 + w_3 x_3)}}.$$

Gib für die Trainingsmenge

$$S = \{((-1, 2, 1), -1), ((2, 6, 1), 1), ((-2, 5, 1), 1), \\ ((3, 0, 1), 1), ((1, 0, 1), -1), ((-3, -1, 1), -1)\}$$

ein w an, sodass alle Punkte aus S durch $\text{sign}(\langle w, x \rangle)$ korrekt klassifiziert werden. Bestimme anschließend die Wahrscheinlichkeiten, die durch deine Wahl von w jedem Punkt aus S durch h_w zugeordnet werden (vgl. Lemma 7.18 im Skript auf der Homepage unter Materialien).

Aufgabe 6.4 (4 Punkte)

Gegeben sei eine Trainingsmenge $S = \{(x_i, y_i)\}_{i=1}^m \in (\mathcal{X} \times \{-1, 1\})^m$, Hypothesen $g_1, \dots, g_T: \mathcal{X} \rightarrow \{-1, 1\}$, sowie $a_1, \dots, a_T \in [0, 1]$ mit $\sum_{i=1}^T a_i = 1$. Es gelte für ein $\theta > 0$, dass

$$y_i \sum_{j=1}^T a_j g_j(x_i) \geq \theta$$

für alle $1 \leq i \leq m$.

- Zeige, dass sich die y_i für alle $1 \leq i \leq m$ durch ein gewichtetes Majoritätskriterium der g_1, \dots, g_T bestimmen lassen.
- Sei D eine Verteilung über $[m]$. Zeige, dass mit obigen Voraussetzungen und $\theta = 2\gamma$ eine Hypothese g_j existiert mit

$$\Pr_{i \sim D}[y_i \neq g_j(x_i)] \leq \frac{1}{2} - \gamma.$$