

MACHINE LEARNING, 9. SEMINAR – MINIMIEREN DES EMPIRISCHEN RISIKOS

Aufgabe 1.

a) Sei $x \in \mathbb{R}$ und $y \in \mathbb{R}$ zwei reellwertige Variablen. Betrachten Sie die folgende Optimierungsaufgabe:

$$\begin{aligned} |x| + |y| &\rightarrow \min_{xy} \\ \text{s.t. } ax + by &\geq 1, \end{aligned}$$

mit reellwertigen Koeffizienten a und b . Geben Sie eine geometrische Interpretation der Aufgabe an und zeigen Sie, dass im Optimum eine der Variablen (d.h. entweder x oder y) gleich Null ist (bei beliebigen a und b).

b) Verallgemeinern Sie diese Aussage auf höhere Dimensionen, d.h. betrachten Sie die Aufgabe

$$\begin{aligned} |x|_1 = \sum_i |x_i| &\rightarrow \min_x \\ \text{s.t. } \langle x, a \rangle &\geq 1, \end{aligned}$$

mit $x, a \in \mathbb{R}^n$.

Aufgabe 2. Zur Klassifikation der Muster $x \in \mathbb{R}$ soll die Schwellwertentscheidung verwendet werden, d.h. $y = \text{sign}(x - \theta)$ mit ± 1 -Kodierung der Klassen und einem Schwellwert θ . Zum Anlernen des unbekanntem Schwellwerts steht die folgende klassifizierte Lernstichprobe zur Verfügung: $L = ((x^l, y^l) \dots) = ((0, -1), (3, +1), (6, -1))$ – sie besteht aus drei Punkten und ist offensichtlich nicht separierbar.

a) Zeichnen Sie den Graph des Empirischen Risikos in Abhängigkeit von θ .

b) Um den optimalen Schwellwert zu finden, wird das Empirische Risiko durch Hinge-Loss ersetzt. Zeichnen Sie den Graph des Hinge-Losses in Abhängigkeit von θ . Vergleichen Sie die beiden Funktionen.

c) Konstruieren Sie eine Lernstichprobe derart, dass das Minimum des Hinge-Losses an solchen Stellen erreicht wird, an welchen das Empirische Risiko maximal ist.

Aufgabe 3. Man betrachte die Entscheidungsregel mit so-geannten „Structured Outputs“. Das Ergebnis ist in diesem Fall nicht ein Wert $y \in \{0, 1\}$, sondern ein binärer Vektor $y \in \{0, 1\}^m$. Sei $x \in \mathbb{R}^n$. Die Entscheidungsregel lautet: $y = \text{sign}(xW)$, wobei W eine $n \times m$ Matrix ist (xW ist die Vektor-Matrix Multiplikation). Der Operator $\text{sign} : \mathbb{R}^m \rightarrow \mathbb{R}^m$ ist die Anwendung des „gewöhnlichen“ sign-Operator komponentenweise. Gegeben sei eine Lernstichprobe der Paare $L = ((x^l, y^l) \dots)$, $x^l \in \mathbb{R}^n$, $y^l \in \mathbb{R}^m$. Man suche nach der Matrix W , die das Empirische Risiko

$$R(e) = \sum_l C(y^l, \text{sign}(x^l W))$$

minimiert.

Denkbar sind dabei zwei Varianten:

a) Die Kostenfunktion ist die einfache $C(y, y') = \delta(y \neq y')$, d.h. eine konstante Strafe wird bezahlt, wenn die soll- und ist-Ergebnisvektoren mit einander nicht *vollständig* übereinstimmen.

b) Die Kostenfunktion ist additiv, d.h. $C(y, y') = \sum_j \delta(y_j \neq y'_j)$ (mit j ist hier die Komponente des Output-Vektors indiziert).

Definieren Sie für beide Fälle eine konvexe (möglichst gute) obere Schranke – verallgemeinern Sie das Hinge-Loss. Wie ergibt sich daraus der Subgradient der zu minimierenden Zielfunktion? Vergleichen Sie beide Varianten.