

Sommersemester 2018

Mario Holldack, M. Sc.  
Prof. Dr. Georg Schnitger  
Hannes Seiwert, M. Sc.

## Übungsblatt 4

Ausgabe: 07.05.2018  
Abgabe: 14.05.2018

Um nachzuweisen, dass ein Entscheidungsproblem  $A$  NP-hart ist, genügt es, ein NP-hartes Problem  $B$  polynomiell auf  $A$  zu reduzieren (kurz  $B \leq_p A$ ):  
Ein Problem  $B$  ist genau dann *polynomiell auf  $A$  reduzierbar*, wenn es eine in Polynomialzeit berechenbare Transformation  $T$  gibt, sodass für jede Eingabe  $x$  von Problem  $B$  gilt:

$$x \in B \iff T(x) \in A$$

### Aufgabe 4.1 *Schnitte von Halbräumen* (10 Punkte)

Zeigen Sie, dass das schwache Konsistenzproblem für die Konzeptklasse aller Schnitte  $H_1 \cap H_2$  zweier Halbräume NP-hart ist.

*Hinweis:* Reduzieren Sie SETSPLITTING auf das schwache Konsistenzproblem. Im SETSPLITTING-Problem sind ein endliches Universum  $U = \{1, \dots, n\}$  und Teilmengen  $T_1, \dots, T_m \subseteq U$  gegeben. Zu entscheiden ist, ob eine Partition  $U = U_1 \dot{\cup} U_2$  existiert, sodass  $T_i \not\subseteq U_j$  für alle  $i = 1, \dots, m$  und  $j = 1, 2$  gilt.

Für eine Eingabe  $U, T_1, \dots, T_m$  konstruieren Sie die transformierte Eingabe, d. h. eine klassifizierte Beispielmenge  $S \subseteq \mathbb{R}^n$  wie folgt:

- Für jedes  $u \in U$  klassifiziere den  $u$ -ten kanonischen Einheitsvektor  $e_u$  negativ.
- Für jedes  $T_i$  klassifiziere den Vektor  $v_{T_i} := \frac{1}{|T_i|} \sum_{t \in T_i} e_t$  positiv.

### Aufgabe 4.2 *k-Klausel-KNF und k-DNF* (5 + 5 Punkte)

In der Vorlesung wurde gezeigt, dass  $k$ -Klausel-KNFs<sup>1</sup> mit der Hypothesenklasse  $k$ -KLAUSEL-KNF vermutlich<sup>2</sup> nicht effizient PAC-lernbar sind. Abhilfe schafft hier die Wahl einer anderen (größeren) Hypothesenklasse.

- a) Zeigen Sie: Für jede  $k$ -Klausel-KNF  $\phi$  existiert eine äquivalente  $k$ -DNF  $\psi$ .
- b) Sei  $k \in \mathbb{N}$  fest. Beschreiben Sie einen effizienten Algorithmus, der das starke Konsistenzproblem für die Hypothesenklasse  $k$ -DNF löst, und bestimmen Sie seine Laufzeit.

**Bitte wenden!**

<sup>1</sup>d. h. KNF-Formeln mit höchstens  $k$  Disjunktionstermen:  $\phi = \bigwedge_{i=1}^k \bigvee_j l_{i,j}$

<sup>2</sup>Sofern  $\text{NP} \not\subseteq \text{RP}$  gilt, d. h. sofern nicht jedes Problem in NP einen effizienten probabilistischen Algorithmus mit einseitig beschränktem Fehler besitzt.

**Aufgabe 4.3** *Schwierigkeit des ERM-Problems im agnostischen Fall* (8 + 4 Punkte)

Wir wissen bereits, wie man das Konsistenzproblem für Monome und Halbräume effizient lösen kann. Nun betrachten wir das Lernen im agnostischen Fall für den 0-1-Loss: Eine endliche Multimenge  $S$  von klassifizierten Beispielen ist gegeben. Eine Hypothese mit der geringsten Anzahl von Fehlklassifikationen – unter allen Hypothesen in der Hypothesenklasse – ist zu bestimmen.

- a) Betrachten Sie die Hypothesenklasse  $\text{MONOTON-MONOM}_n$  aller monotoner Monome über  $n$  Variablen. (Ein monotoner Monom ist eine Konjunktion positiver Literale.)  
Zeigen Sie: Das schwache ERM-Problem<sup>3</sup> für  $(\text{MONOTON-MONOM}_n)_{n \in \mathbb{N}}$  ist NP-hart.
- b) Betrachten Sie die Hypothesenklasse  $\text{RECHTECK}_n$  aller  $n$ -dimensionaler Rechtecke.  
Zeigen Sie: Das schwache ERM-Problem für  $(\text{RECHTECK}_n)_{n \in \mathbb{N}}$  ist NP-hart.

*Hinweis:* Sie können dieselbe Transformation wie in Teil a) verwenden.

*Hinweis:* Sie können jeweils  $\text{VERTEXCOVER}$  auf das ERM-Problem reduzieren. Wählen Sie jeweils  $n$  als die Anzahl der Knoten  $|V|$ .

Folgende Vorgehensweise ist zu empfehlen: Stellen Sie Knoten durch positive Beispiele und Kanten durch negative Beispiele dar – oder umgekehrt. Sie können Beispiele mehrfach erstellen und dadurch eine Gewichtung der Beispiele simulieren. Wählen Sie die Gewichte der „Kanten-Beispiele“ hinreichend groß, um zu gewährleisten, dass jede Lösung des ERM-Problems Fehlklassifizierungen nur auf „Knoten-Beispielen“ machen kann.

Beschreiben Sie Ihre Transformation und führen Sie den Nachweis der Äquivalenz. Eine Begründung der Laufzeit ist nicht nötig.

**Bonusaufgabe 4.4.** *Rechtecke lernen mit verrauschten Beispielen* (3 + 5 Extrapunkte)

Wir betrachten das ERM-Problem für die die Konzeptklasse  $\text{RECHTECK}_d$  aller  $d$ -dimensionalen Rechtecke:

Gegeben ist eine Menge  $S \subseteq \mathbb{R}^d \times \{0, 1\}$  von  $s$  klassifizierten Beispielen.  
Gesucht ist ein Rechteck  $R_{a,b}$ , welches den 0-1-Loss bzgl.  $S$  minimiert.

- a) Beschreiben Sie einen Algorithmus mit möglichst geringer Laufzeit, der das Problem für  $d=1$  löst. Analysieren Sie auch die Laufzeit Ihres Algorithmus (in Abhängigkeit von  $s$ ).

In Aufgabe 4.3 b) haben wir gezeigt, dass das ERM-Problem für allgemeines  $d \in \mathbb{N}$  NP-hart ist. Dabei sind wir allerdings davon ausgegangen, dass die Beispielmenge  $S$  „böartig“ gewählt werden darf. Wir betrachten nun den Fall einer Beispielmenge  $S$ , die von einer „gutartigen“ Verteilung zufällig erzeugt wird.

- b) Gegeben sei ein (unbekanntes) Zielkonzept  $c \in \text{RECHTECK}_d$ . Die Beispiele  $x_i$  werden gemäß der Gleichverteilung auf  $[0, 1]^d$  zufällig gezogen. Beispiele  $x_i$  innerhalb von  $c$  werden mit Wahrscheinlichkeit  $1 - \eta$  positiv klassifiziert, Beispiele  $x_i$  außerhalb  $c$  werden mit Wahrscheinlichkeit  $1 - \eta$  negativ klassifiziert. Dabei sei  $0 < \eta \leq 1/4$ .

Beschreiben Sie eine *effiziente* Heuristik, die für diesen Fall mit guter Wahrscheinlichkeit „vernünftige“ Ergebnisse liefert. Eine „hand-waving“ Argumentation, warum Ihr Ansatz sinnvoll ist, genügt. Eine mathematische Analyse ist nicht verlangt.

---

<sup>3</sup>siehe Definition 6.11 im Skript