

unter Verwendung des polynomischen PAC-Lernalgorithmus zum Lernen von Monomen.

Die Ausgabe des Lernalgoritmus kann durch Ersetzen jeder Variablen  $x_{uvw}$  durch seine korrespondierende Konszel ( $uvvw$ ) wieder als Ausdruck in 3-LNF geschrieben werden.

$\Rightarrow$

Wenn wir erlauben, dass die Ausgabe des Lernalgoritmus ein Ausdruck in 3-LNF ist, dann gibt es einen polynomischen PAC-Lernalgoritmus für Ausdrücke in 3-Term DNF.

Übung:

Zeigen Sie, dass die Ausgabe des obigen Lernalgoritmus nicht notwendigerweise äquivalent zu einem Ausdruck in 3-Term-DNF ist.

## 5.2 Ockhams Rasiermesserprinzip

Ockhams Rasiermesserprinzip besagt, dass das einfachste mit den Beispielen konsistente Konzept als Ausgabe des Lernalgoritmus gewählt werden soll.

### Problem

Einfachste oder auch kürzeste Konzepte können

häufig überhaupt nicht oder nur mit zu großem Zeitaufwand berechnet werden.

Beispiel:

Die Berechnung eines kürzesten Ausdrucks in DNF mit maximal  $k$  Literalen pro Monom, der mit einer gegebenen Menge von Beispielen konsistent ist, ist NP-hart.



Betrachte polynomiale berechenbare Approximationen von kürzesten Konzepten.

Seien  $C$  eine Konzeptklasse,  $d \geq 1$  und  $0 \leq \alpha < 1$  Konstanten. Ein  $(d, \alpha)$ -Ockham-Algorithmus für  $C$  ist ein Lernalgorithmus  $O_I$ , der folgende Eigenschaften besitzt:

- i) Gegeben  $m$  Beispiele für ein beliebiges zu lernendes Konzept  $c \in C$  der Länge  $\leq s$  Bits gibt der Algorithmus  $O_I$  ein zu den Beispielen konsistentes Konzept  $c' \in C$  der Länge  $\leq s^d m^\alpha$  aus.
- ii)  $O_I$  hat in  $m$  polynomiale Laufzeit.

Satz 5.3

Seien  $C$  eine Konzeptklasse,  $d \geq 1$  und  $0 \leq \alpha < 1$  Konstanten. Falls  $C$  einen  $(d, \alpha)$ -Ockham-

Algorithmus  $\sigma_1$  besitzt, dann ist  $C$  polynomial PAC-lernbar.

### Beweis:

Sei  $P$  die Wahrscheinlichkeitsverteilung, mittels der der Lernalgorithmus  $\sigma_1$  die Beispiele unabhängig voneinander aus  $S$  wählt.

Betrachten wir Fehlerparameter  $0 < \varepsilon < 1$  und Vertrauensparameter  $0 < \delta < 1$  beliebig aber fest.

### Idee:

Wähle  $m$  groß genug, so dass gezeigt werden kann, dass der  $(d, \alpha)$ -Ockham-Algorithmus auch ein PAC-Lernalgorithmus ist.

Sei

$$m \geq \max \left\{ \left( \frac{2(s^d + 1)}{-\log(1-\varepsilon)} \right)^{\frac{1}{1-\alpha}}, \frac{2 \cdot \log \frac{1}{\delta}}{-\log(1-\varepsilon)} \right\}$$

Die Wahl von  $m$  ergibt sich aus den nachfolgenden Berechnungen.

Konstruktion  $\Rightarrow$

$m$  ist polynomial in  $s$ ,  $\frac{1}{\varepsilon}$  und  $\frac{1}{\delta}$ .

$\sigma_1$   $(d, \alpha)$ -Ockham-Algorithmus  $\Rightarrow$

$\sigma_1$  gibt ein Konzept  $c'$  der Länge  $\leq s^d m^\alpha$  aus.

2.2.

$$\Pr \left( \sum_{v: f_c(v) \neq f_{\bar{c}}(v)} P(v) > \varepsilon \right) < \delta.$$

Betrachten wir hierzu folgende Teilmenge  $C'$  von  $C$ :

$$C' := \{ \bar{c} \in C \mid |\bar{c}| \leq s^d m^\alpha \}.$$

$\Rightarrow$

$$c' \in C'.$$

Sei  $r := |C'|$ .

### Lemma 5.1

Sei  $\bar{c} \in C'$  ein beliebiges Konzept in  $C'$ , das sich bei  $m$  unabhängig gewählten Beispielen bezüglich der Werte der charakteristischen Funktion genauso wie des zu lernende Konzept  $c$  verhält. Dann gilt:

$$\Pr \left( \sum_{v: f_c(v) \neq f_{\bar{c}}(v)} P(v) \geq \varepsilon \right) < (1-\varepsilon)^m r$$

Bevor wir das Lemma beweisen, führen wir den Beweis des Satzes zu Ende.

Wegen

$$m \geq \left( \frac{2(s^d + 1)}{-\log(1-\varepsilon)} \right)^{\frac{1}{1-\alpha}}$$

gilt:

$$m^{1-\alpha} \geq \frac{2(s^d + 1)}{-\log(1-\varepsilon)}$$

$$\Leftrightarrow s^d m^\alpha + m^\alpha \leq -\frac{1}{2} m \log(1-\varepsilon).$$

Somit erhalten wir wegen  $m^\alpha \geq 1$ :

$$\begin{aligned} r &\leq 2^{s^d m^\alpha + 1} \\ &\leq 2^{-\frac{m}{2} \log(1-\varepsilon)} \\ &= (1-\varepsilon)^{-\frac{m}{2}} \end{aligned}$$

Lemma 5.1  $\Rightarrow$

$$\begin{aligned} \Pr_r \left( \sum_{v: f_c(v) + f_{\bar{c}}(v)} P(v) \geq \varepsilon \right) &< (1-\varepsilon)^m \cdot r \\ &\leq (1-\varepsilon)^m \cdot (1-\varepsilon)^{-\frac{m}{2}} \\ &= (1-\varepsilon)^{\frac{m}{2}} \end{aligned}$$

Wegen

$$m \geq \frac{\lambda \cdot \log \frac{1}{\delta}}{-\log(1-\varepsilon)} \quad \text{gilt:}$$

$$\begin{aligned} (1-\varepsilon)^{\frac{m}{2}} &\leq (1-\varepsilon)^{\frac{\log \frac{1}{\delta}}{-\log(1-\varepsilon)}} \\ &= 2^{\frac{\log(1-\varepsilon) \log \frac{1}{\delta}}{-\log(1-\varepsilon)}} \end{aligned}$$

$$\begin{aligned}
 &= 2^{\log \delta} \\
 &= \delta.
 \end{aligned}$$

Also gilt

$$\Pr\left(\sum_{v: f_c(v) \neq f_{\bar{c}}(v)} P(v) \geq \varepsilon\right) < \delta,$$

So dass unser Satz unter der Voraussetzung, dass das Lemma 5.1 korrekt ist, bewiesen ist. ■

Bew. von Le 5.1:

Sei

$$B := \left\{ \bar{c} \in C' \mid \sum_{v: f_c(v) \neq f_{\bar{c}}(v)} P(v) \geq \varepsilon \right\}.$$

Betrachten wir  $\bar{c} \in B$ . Bezeichne  $E_{\bar{c}}$  das Ereignis, dass sich  $\bar{c}$  bei allen in unabhängig gewählten Beispielen bezüglich der Werte der charakteristischen Funktion genauso wie das zu lernende Konzept  $c$  verhält.

Für jedes  $\bar{c} \in B$  ist die Wahrscheinlichkeit, dass sich  $c$  und  $\bar{c}$  für ein zufälliges Beispiel unterscheiden  $\geq \varepsilon$ .

Dar die in Beispiele unabhängig gemäß der

Wahrscheinlichkeitsverteilung  $P$  gewählt werden, gilt:

$$\Pr(E_{\bar{c}}) < (1-\varepsilon)^m.$$

Hieraus folgt wegen  $|B| \leq |C'| = r$

$$\Pr\left(\bigcup_{\bar{c} \in B} E_{\bar{c}}\right) < (1-\varepsilon)^m \cdot r.$$

■

### 5.3 Samplekomplexität von PAC-Lernalgorithmen

Frage:

Gibt es eine Beziehung zwischen der Anzahl der zum Lernen benötigten Beispielen und interessante Eigenschaften der zugrunde liegenden Konzeptklasse?

Ziel: Beantwortung obiger Frage.

Sei  $O_1$  ein Lernalgorithmus für eine Konzeptklasse  $C$ . Dann heißt die Funktion

$$s: (0,1] \times (0,1] \times \mathbb{N} \rightarrow \mathbb{N},$$

wobei  $s(\varepsilon, \delta, n)$  die maximale Anzahl der Befragungen des Oracle des EXAMPLE durch  $O_1$  bei Eingabe  $\varepsilon, \delta$  und  $n$  ist, Samplekomplexität des Lernalgorithmus  $O_1$ . Dabei wird

das Maximum über alle zu lernenden Konzepte  $c \in C$  und alle Wahrscheinlichkeitsverteilungen  $P$  auf  $S^{\leq n}$  genommen.

Eine Konzeptklasse  $C$  heißt polynomiel  
Samplebar, falls ein Lernalgorithmus  $\mathcal{A}$  für  $C$  und ein Polynom  $p$  existieren, so dass  
 $\forall (\varepsilon, \delta, n) \in (0,1] \times (0,1] \times \mathbb{N}$  stets  
 $s(\varepsilon, \delta, n) \leq p\left(\frac{1}{\varepsilon}, \frac{1}{\delta}, n\right)$ .

Seien  $C$  eine Konzeptklasse mit zugehörigen Ereignisraum  $S$  und  $S' \subseteq S$  eine Beispielmenge. Dann besteht  $\Pi_C(S')$  genau aus denjenigen Teilmengen von  $S'$ , die sich als Durchschnitt eines Konzeptes  $c \in C$  mit  $S'$  schreiben lassen. D.h.,

$$\Pi_C(S') := \{c \cap S' \mid c \in C\}.$$

Wir sagen  $C$  zerlegt  $S' \subseteq S$ , falls  $\Pi_C(S')$  die Potenzmenge von  $S'$  ist; d.h.,

$$\Pi_C(S') = 2^{S'}$$

Beispiel:

Seien

- $S := \mathbb{N}_0$  der Ereignisraum
- $S' := \{0, 1, 2\}$  eine Beispielmenge und

$$C := \left\{ \{\{0, 2, 4\}, \{0, 4\}, \{2\}, \{4\}, \{0, 2\}, \right. \\ \left. \{0, 1, 2\}, \{1, 2\}, \{1, 4\}, \{0, 1, 4\} \right\}$$

Dann zerlegt  $C$  die Beispielmenge  $S'$ .  
(Überzeugen Sie sich). ◆

### Interpretation:

Wenn  $C$  die Menge  $S' \subseteq S$  zerlegt, dann ist jedes Beispiel  $x \in S'$  von den anderen Beispielen in  $S'$  unabhängig. D.h., das Wissen  $x \in C$  für ein Konzept  $c$  sagt nichts über das Enthaltensein irgendeines anderen Beispiels  $y \in S'$  in  $c$  aus. Je größer die Elementanzahl einer Menge, die von einer Konzeptklasse  $C$  zerlegt wird, umso schwieriger ist es, die Konzeptklasse  $C$  zu lernen.

Die Vapnik-Chervonenkis (VC) - Dimension  $D_{VC}(C)$  von  $C$  ist das maximale  $d \in \mathbb{N}$ , so dass  $S' \subseteq S$  mit  $|S'| = d$  und  $C$  zerlegt  $S'$  existiert.

### Bemerkung:

- Um zu beweisen, dass die VC-Dimension einer Konzeptklasse  $C$  mindestens  $d$  ist, genügt es eine Beispielmenge  $S'$  der Größe

d zu konstruieren und zu zeigen, dass  $C$  die Beispielmenge  $S'$  zerlegt.

- Um zu zeigen, dass die VC-Dimension einer Konzeptklasse  $C$  höchstens  $d$  ist muss genügt werden, dass jede Beispielmenge der Größe  $d+1$  nicht von  $C$  zerlegt wird.
- Um für eine Beispielmenge  $S'$  zu zeigen, dass diese nicht von einer Konzeptklasse  $C$  zerlegt wird, genügt es, für eine Teilmenge  $S'' \subseteq S'$  zu beweisen, dass kein Konzept  $c \in C$  mit  $c \cap S' = S''$  existiert.

### Beispiel:

Wir betrachten zwei geometrische Konzeptklassen und berechnen ihre VC-Dimension.

9) Seien

- die reelle Gerade des Ereignisraum  $S$ , und
- die Menge der abgeschlossenen Intervalle auf  $S$ , die Konzeptklasse  $C_1$ .

$\Rightarrow$

$C_1$  zerlegt jede Beispielmenge bestehend aus zwei beliebigen Punkten auf  $S$ ,

aber

$\nexists$  Beispielmenge  $S'_1$  bestehend aus drei Punkten

auf  $S_1$ , die  $C_1$  zerlegt.

$\Rightarrow$

VC-Dimension der Konzeptklasse  $C_1$  ist zwei.

b)

Seien

- die reelle Ebene der Ereignisraum  $S_2$  und
- die Menge der Halbebenen von  $S_2$  die Konzeptklasse  $C_2$ .

Sei  $S'_2$  eine Menge von drei beliebigen Punkten in  $S_2$ , die nicht auf einer Geraden liegen.

$\Rightarrow$

$C_2$  zerlegt die Beispielmenge  $S'_2$ .

$\Rightarrow$

VC-Dimension der Konzeptklasse  $C_2$  ist  $\geq$  drei

Betr.: VC-Dimension von  $C_2$  ist  $<$  vier.

Bew.:

$S'_2$

Betrachte vier beliebige Punkte in der Ebene.  
Drei Fälle können eintreten

1) Mindestens drei der Punkte liegen auf derselben Gerade.

- 2) Es liegen maximal zwei Punkte auf der selben Gerade und alle vier Punkte liegen auf der von ihnen definierten konvexen Hülle.
- 3) Drei der vier Punkte definieren die konvexe Hülle und der vierte Punkt liegt im Inneren der konvexen Hülle.

Wir diskutieren die drei Fälle nacheinander.

#### 1. Fall:

$\nexists$  Halbsebene, die von drei Punkten auf der selben Gerade die beiden äußersten Punkte und nicht den inneren Punkt enthält.

$\Rightarrow$

$C_2$  zerlegt Beispielmenge  $S_2'$  nicht.

#### 2. Fall:

$O_+$

$O_-$

$O_-$

$O_+$

Betrachte Beispielmenge  $S_2''$ , die aus zwei auf der konvexen Hülle gegenüberliegenden Punkten besteht.  $\nexists$  Halbsebene, die die Punkte in  $S_2''$  und nicht mindestens einen Punkt in  $S_2' \setminus S_2''$  enthält.  $\Rightarrow C_2$  zerlegt die Beispielmenge  $S_2'$  nicht.

3. Fall $O_+$  $O^+$  $O_-$  $O'_+$ 

Betrachte die Beispielmenge  $S_2''$ , die exakt die drei Punkte auf der konvexen Hülle enthält.

$\nexists$  Hilfsebene, die  $S_2''$  und nicht den Punkt in  $S_2' \setminus S_2''$  enthält.

$\Rightarrow C_2$  zerlegt Beispielmenge  $S_2'$  nicht ■

Insgesamt gilt

$$\mathcal{D}_{VC}(C_2) = 3.$$

Übung:

Seien die euklidische Ebene  $\mathbb{R}^2$  der Ereignisraum  $S$  und die Menge aller zu den Koordinatenachsen parallelen Rechtecke die Konzeptklasse  $C$ . Zeigen Sie, dass vier die VC-Dimension von  $C$  ist.

Lemma 5.2

Seien  $S$  eine endliche Menge,  $C$  eine Konzeptklasse mit zugehörigen Ereignisraum  $S$  und

$d := D_{VC}(C)$ . Dann gilt

$$2^d \leq |C| \leq (|S| + 1)^d.$$

Beweis:

Sei  $C$  eine Menge  $S' \subseteq S$  mit  $|S'| = 0$  z.z. liegt und die Anzahl der verschiedenen Teilmengen von  $S'$  gerade  $2^d$  ist, muss  $C$  mindestens  $2^d$  verschiedene Konzepte enthalten.

Die obere Schranke beweisen wir mittels Induktion über  $|S|$ .

$|S| = 1$ :

Dann existieren nur die Konzeptklassen

$$\{\emptyset\}, \{S\} \text{ und } \{\emptyset, S\}.$$

Die Konzeptklassen  $\{\emptyset\}$  und  $\{S\}$  haben die VC-Dimension 0.  $\{\emptyset, S\}$  hat VC-Dimension 1. Also gilt offensichtlich die obere Schranke.

Annahme:

$|C| \leq (|S| + 1)^d$  für alle Ereignisräume  $S$  mit  $|S| = k$ ,  $k \geq 1$ .

$k \rightsquigarrow k+1$ :

Sei  $|S| = k+1$ . Betrachten wir  $x \in S$  beliebig aber fest. Seien

$$S_1 := S \setminus \{x\},$$

$$C_1 := \{c_i \in C \mid \exists c \in C \setminus \{c_i\} \text{ mit } c_i = c \cup \{x\}\}$$

$$C_2 := C \setminus C_1.$$

Idee:

Herleitung von oberen Schranken für  $|C_1|$  und  $|C_2|$ . Dessen Summe ist dann eine obere Schranke für  $|C|$ .

Konstruktion  $\Rightarrow$

Zwei verschiedene Konzepte in  $C_2$  können sich nicht nur bezüglich  $x$  unterscheiden.

$\Rightarrow$

Die Konzepte in  $C_2$  können mittels Beispiele in  $S_1$  unterschieden werden.

$\Rightarrow$

Wir können  $C_2$  als Konzeptklasse mit zu gehöriger Ereignismenge  $S_1$  interpretieren, ohne dass sich hierdurch die Elementanzahl von  $C_2$  ändert würde.

Wegen  $C_2 \subseteq C$  kann  $C_2$  keine größere Menge zerlegen als  $C$ .

$\Rightarrow$

$$D_{VC}(C_2) \leq d.$$

Wegen  $|S_1| = \varepsilon$  ist die Induktionsannehme anwendbar.

$\Rightarrow$

$$|C_2| \leq (|S_1| + 1)^d.$$

Da alle Konzepte in  $C_1 \times$  enthalten, unterscheiden sich verschiedene Konzepte in  $C_1$  durch Beispiele aus  $S_1$ .

Ziel: Beweis, dass  $D_{VC}(C_1) < d$ .

Annahme:  $C_1$  zerlegt  $S' \subseteq S_1$  mit  $|S'| \geq d$ .

Konstruktion von  $C_1$  und  $C_2 \Rightarrow$

$C$  zerlegt  $S' \cup \{x\}$ .

Wegen

$$|S' \cup \{x\}| \geq d+1 \text{ und } D_{VC}(C) = 0$$

kann dies nicht sein.

$\Rightarrow$

Teilmengen von  $S_1$ , die  $C_1$  zerlegt, enthalten höchstens  $d-1$  Elemente.

Induktionsannahme  $\Rightarrow$

$$|C_1| \leq (|S_1| + 1)^{d-1}.$$

Insgesamt erhalten wir

$$|C| = |C \setminus C_1| + |C_1|$$

$$\geq |C_2| + |C_1|$$

$$\begin{aligned}
 &\leq (|S_1|+1)^d + (|S_1|+1)^{d-1} \\
 &= (k+1)^d + (k+1)^{d-1} \\
 &= (k+2)(k+1)^{d-1} \\
 &\leq (k+2)^d \\
 &= (|S_1|+1)^d
 \end{aligned}$$

### Ziel:

Herausarbeitung eines Zusammenhangs zwischen VC-Dimension und polynomialer Sample Lernbarkeit.

Nachfolgend ist stets  $\Sigma = \{0, 1\}$ .

Seien  $C$  eine Konzeptklasse mit zugehörigen Ergebnisraum  $\Sigma^*$  und  $c \in C$ . Die Projektion  $c^{\leq n}$  von  $c$  auf  $\Sigma^{\leq n}$  ist definiert durch

$$c^{\leq n} := c \cap \Sigma^{\leq n}.$$

Die Projektion  $C^{\leq n}$  von  $C$  auf  $\Sigma^{\leq n}$  ist dann definiert durch

$$C^{\leq n} := \{c^{\leq n} \mid c \in C\}.$$

Die Funktion  $d: \mathbb{N} \rightarrow \mathbb{N}$  mit

$$d(n) = D_{VC}(C^{\leq n}) \quad \forall n \in \mathbb{N}$$

heißt asymptotische VC-Dimension der Konzeptklasse  $C$ . Diese bezeichnen wir mit  $D_{VC}^a(C)$ .

Wir sagen,  $C$  hat polynomiale VC-Dimension, falls ein Polynom  $p$  existiert, so dass

$$D_{VC}^a(C)(n) = O(p(n)) \quad \forall n \in \mathbb{N}.$$

Folgendes Lemma folgt direkt aus Lemma 5.2:

### Lemma 5.3

Seien  $n \in \mathbb{N}$  und  $d = D_{VC}(C^{\leq n})$ . Dann gilt

$$2^d \leq |C^{\leq n}| \leq 2^{(n+1)d}$$

### Beweis:

Nach Substitution von  $C^{\leq n}$  für  $C$  und von  $\Sigma^{\leq n}$  für  $S$  in Lemma 5.2 erhalten wir wegen

$$|\Sigma^{\leq n}| \leq 2^{n+1} - 1 :$$

$$2^d \leq |C^{\leq n}| \leq (2^{n+1} - 1 + 1)^d = 2^{(n+1)d}.$$

■

### Ziel:

Entwicklung eines Lernalgoritmus für Konzeptklassen mit Ereignisraum  $\Sigma^*$ , dessen Samplekomplexität mit Hilfe der asymptotischen VC-Dimension der Konzeptklasse ausgedrückt werden kann.

### Satz 5.4

Sei  $C$  eine Konzeptklasse mit zugehörigen Ergebnisraum  $\Sigma^*$ . Dann existiert ein Lernalgorithmus  $O_{VC}$  für  $C$  mit Sample Komplexität

$$S(\varepsilon, \delta, n) = \lceil \frac{1}{\varepsilon} ((n+1) D_{VC}(C^{\leq n}) \ln 2 + \ln \frac{1}{\delta}) \rceil.$$

### Beweis:

Betrachten wir folgenden Lernalgorithmus für  $C$ :

#### Algorithmus $O_{VC}$

Eingabe:  $\varepsilon, \delta \in (0, 1]$ ,  $n \in \mathbb{N}$ .

Ausgabe:  $g \in C$ .

#### Methode:

$$m := \frac{1}{\varepsilon} ((n+1) D_{VC}(C^{\leq n}) \ln 2 + \ln \frac{1}{\delta});$$

Befrage EXAMPLE  $m$ -mal;

(\* Sei  $Z$  die Menge der gesehenen Beispiele. \*)

Ermittle ein mit  $Z$  konsistentes Konzept  $g \in C$ ;

Ausgabe :=  $g$ .

#### Ziel:

Beweis, dass der Algorithmus  $O_{VC}$  die erforderlichen Eigenschaften besitzt.

Sei  $c \in C$  das zu lernende Konzept. Dann ist

$$\Pr \left( \sum_{v: f_c(v) \neq f_g(v)} P(v) < \varepsilon \right) \geq 1 - \delta$$

zu beweisen. Der Beweis verläuft ähnlich zum Beweis des Lemmas 5.1. Sei

$$B^{\leq n} := \left\{ h^{\leq n} \in C^{\leq n} \mid \sum_{v \in \Sigma^{\leq n}: f_c(v) \neq f_{h^{\leq n}}(v)} P(v) \geq \varepsilon \right\}.$$

Für jedes  $g^{\leq n} \in B^{\leq n}$  ist die Wahrscheinlichkeit, dass sich  $f_c(v)$  und  $f_{g^{\leq n}}(v)$  für ein zufällig gewähltes Beispiel  $v \in \Sigma^{\leq n}$  unterscheiden, mindestens  $\varepsilon$ .

Berechne  $E_{g^{\leq n}}$  des Ereignis, dass  $g^{\leq n}$  bei allen  $m$  unabhängig gewählten Beispielen sich bzgl. der Werte der charakteristischen Funktion genauso wie  $c$  verhält. Dann gilt

$$\Pr(E_{g^{\leq n}}) \leq (1 - \varepsilon)^m.$$

Da  $c \notin B^{\leq n}$  und somit  $|B^{\leq n}| < |C^{\leq n}|$  erhalten wir

$$\Pr \left( \bigcup_{g^{\leq n} \in B^{\leq n}} E_{g^{\leq n}} \right) < |C^{\leq n}| \cdot (1 - \varepsilon)^m.$$

Idee:

Wähle  $m$  groß genug, so dass  $|C^{\leq n}| \cdot (1 - \varepsilon)^m \leq \delta$ .

Lemma 5.2  $\Rightarrow$

$$|C^{\leq n}| \leq 2^{(n+1)D_{VC}(C^{\leq n})}.$$

Somit genügt es m derart zu wählen, dass

$$2^{(n+1)D_{VC}(C^{\leq n})} (1-\varepsilon)^m \leq \delta.$$

$$\Leftrightarrow (n+1)D_{VC}(C^{\leq n}) \ln 2 + m \cdot \ln(1-\varepsilon) \leq \ln \delta.$$

Wegen  $\ln(1+x) \leq x$  genügt es zu zeigen, dass

$$(n+1)D_{VC}(C^{\leq n}) \ln 2 - m\varepsilon \leq \ln \delta$$

$$\Leftrightarrow m \geq \frac{1}{\varepsilon} \left( (n+1)D_{VC}(C^{\leq n}) \ln 2 + \ln \frac{1}{\delta} \right).$$

Also gilt für  $m \geq \frac{1}{\varepsilon} \left( (n+1)D_{VC}(C^{\leq n}) \ln 2 + \ln \frac{1}{\delta} \right)$

$$\Pr \left( \sum_{v \in \Sigma^{\leq n}: f_C(v) \neq f_{g^{\leq n}}(v)} P(v) < \varepsilon \right) \geq 1 - \delta,$$

wobei g konsistent mit allen in unabhängig gewählten Beispielen ist.

■

Nach Einsetzen von  $p(n)$  für  $D_{VC}(C^{\leq n})$  in  $\frac{1}{\varepsilon} \left( (n+1)D_{VC}(C^{\leq n}) \ln 2 + \ln \frac{1}{\delta} \right)$  für ein Polynom p erhalten wir wiederum ein Polynom.

Also impliziert Satz 5.4 direkt folgendes Korollar:

### Korollar 5.1

Sei C eine Konzeptklasse mit zugehörigem Ergebnisraum  $\Sigma^*$  und polynomieller VC-Dimension. Dann ist C polynomial samplebar.

Folgende Frage stöngt sich auf:

Wie gut ist Setz 5.4?

Da wir in obiger Analyse als obere Schranke für  $|B^{\leq n}|$  ein  $|C^{\leq n}| - 1$  genommen haben, könnte man sich zunächst fragen, ob wir obige Analyse des Lemalgoritmus verbessern können. In der Tat kann man durch eine kompliziertere Analyse in obiger oberen Schranke  $n$  durch eine Konstante ersetzen.

Siehe: M.J. Kearns, U.V. Vazirani, An Introduction

...

Des Weiteren ist es zur Beantwortung obiger Frage sinnvoll, sich Gedanken über untere Schranken für die Samplekomplexität einer Konzeptklasse  $C$  in Abhängigkeit seiner asymptotischen VC-Dimension zu machen.

### Setz 5.5

Jeder PAC - Lemalgoritmus für eine Konzeptklasse  $C$  bei einem Fehlerparameter  $\varepsilon < \frac{1}{4}$  Samplekomplexität  $s(\varepsilon, \delta, n) \geq \frac{1}{8\varepsilon} D_{VC}(C^{\leq n})$ .

Beweis:

Idee:

Konstruiere auf dem Ereignisraum  $S$  eine Wahrscheinlichkeitsverteilung  $P$ , die jeden

PAC-Lernalgorithmus zwingt, viele Beispiele zu betrachten.

### Durchführung:

Seien  $d := D_{VC}(C^{\leq n})$  und  $S' := \{x_1, x_2, \dots, x_d\}$  eine Beispielmenge, die von  $C^{\leq n}$  zerlegt wird.

Betrachten wir die Wahrscheinlichkeitsverteilung  $P$ , die jedem Beispiel in  $S'$  die Wahrscheinlichkeit  $\frac{1}{d}$  und jedem anderen Beispiel die Wahrscheinlichkeit 0 zuordnet.

Sei  $c$  das zu lernende Konzept.

### Annahme:

Ein Lernalgorithmus  $OI$  befragt bei obiger Wahrscheinlichkeitsverteilung  $m$ -mal EXAMPLE.

Für den Beweis der unteren Schranke können wir O.B.d.A. annehmen, dass EXAMPLE stets ein neues Beispiel aus  $S'$  auswählt.

Sei  $S'' \subseteq S'$  mit  $|S''| = m$  die Menge der Beispiele, die  $OI$  aufgrund seiner Befragungen von EXAMPLE kennt.

$C^{\leq n}$  zerlegt die Beispielmenge  $S' \Rightarrow$

$OI$  hat bezüglich jedem Beispiel  $x \in S' \setminus S''$  keine Information, ob  $x \in C^{\leq n}$  oder nicht.

$\Rightarrow$

Für jede der möglichen  $2^{d-m}$  Teilmengen von  $S' \setminus S''$  gibt es in  $C^{\leq n}$  ein mit  $S'$  konsistentes Konzept, das von den Beispielen in  $S' \setminus S''$  exakt diese Teilmenge enthält.

Sei  $B \subseteq C$  eine Menge von Konzepten, die für jede Teilmenge von  $S' \setminus S''$  exakt ein solches Konzept enthält.

$\Rightarrow$

$$|B| = 2^{d-m}$$

Sei  $h$  die Ausgabe von  $O_1$ .

Für jedes Beispiel  $x \in S' \setminus S''$  gilt für exakt der Hälfte der Konzepte in  $B$ , dass diese und  $h$  sich unterschiedlich bzgl.  $x$  verhalten.

$\Rightarrow$

$$\sum_{C \in B} \sum_{(x \in S' \setminus S'': f_C(x) \neq f_h(x)} P(x) = \frac{(d-m) 2^{d-m}}{2^d}$$

$\Rightarrow$

$\exists c_0 \in B$ , so dass

$$\sum_{x \in S' \setminus S'': f_{c_0}(x) \neq f_h(x)} P(x) = \frac{d-m}{2^d}.$$

Für  $m \leq \frac{d}{2}$  gilt dann

$$\sum_{x \in S' \setminus S'': f_{C_0}(x) \neq f_u(x)} P(x) \geq \frac{1}{4}.$$

Da sich EXAMPLE bezüglich  $S''$  für alle zu lernenden Konzepte in  $\mathcal{B}$  gleich verhält, können wir aus  $\mathcal{B}$  jedes Konzept als das zu lernende Konzept auswählen, ohne dass sich hierdurch die Ausgabe von  $\Theta$  ändern würde. Also gilt

$$S(\varepsilon, \delta, u) > \frac{D_{VC}(C^{\leq u})}{2}.$$

Idee:

Um in die untere Schranke die gewünschte Abhängigkeit von dem Fehlerparameter  $\varepsilon$  hineinzubekommen, modifizieren wir obige Wahrscheinlichkeitsverteilung  $P$ , so dass die Wahrscheinlichkeiten von  $\varepsilon$  abhängen.

Durchführung:

Sei die Wahrscheinlichkeitsverteilung  $Q$  definiert durch

$$1) \quad Q(x_1) := 1 - 4\varepsilon,$$

$$2) \quad Q(x_i) := \frac{4\varepsilon}{d-1} \quad 2 \leq i \leq d \text{ und}$$

$$3) \quad Q(x) := 0 \quad \forall x \in S \setminus S'.$$

Bei der Wahrscheinlichkeitsverteilung  $Q$  be-

trägt die erwartete Anzahl von Befragungen an EXAMPLE, damit von EXAMPLE ein Beispiel aus  $\{x_2, x_3, \dots, x_{01}\}$  gewählt wird  $\frac{1}{4\varepsilon}$ .

$\Rightarrow$

Mindstens  $\frac{m}{4\varepsilon}$  Befragungen von EXAMPLE werden benötigt, damit der Algorithmus OI mindestens  $m$  unterschiedliche Beispiele kennlert.

Für  $m := \frac{d}{2}$  ergibt dies die Anzahl  $\frac{d}{8\varepsilon}$ .

Analog zu oben zeigt man nun

$$S(\varepsilon, \delta, n) > \frac{D_{VC}(C^{\leq n})}{8\varepsilon} \quad \text{Übung}$$