



10. Übungsblatt - Lösungen

Aufgabe 1 (Covering Numbers von Baumstümpfen)

Lösung:

(a) Mit dem Satz gilt:

$$\begin{aligned}
 N(\varepsilon, \mathcal{C}, \|\cdot\|_{2,n,X}) &\leq 13 \cdot \mathcal{V}(\mathcal{C}) \cdot \left(\frac{4e}{\varepsilon}\right)^{\mathcal{V}(\mathcal{C})} \\
 &= \left(\frac{4e(13\mathcal{V}(\mathcal{C}))^{\frac{1}{2\mathcal{V}(\mathcal{C})}}}{\varepsilon}\right)^{2\mathcal{V}(\mathcal{C})} \\
 &\stackrel{\forall x > 0: x^{1/2x} \leq 2}{\leq} \left(\frac{13 \cdot 2 \cdot 4e}{\varepsilon}\right)^{2\mathcal{V}(\mathcal{C})} \\
 &\stackrel{2\mathcal{V}(\mathcal{C}) \leq V}{\leq} \left(\frac{13 \cdot 2 \cdot 4e}{\varepsilon}\right)^V.
 \end{aligned}$$

(b) Zur Berechnung von $m_{\mathcal{C}}(N)$ bzw. zumindest einer unteren Schranke müssen überlegen, wie viele verschiedene Labelings von N Punkten im Raum durch Baumstumpf-Entscheidungsregeln erreicht werden können. Hierbei darf man sich die Lage der Punkte im Raum aussuchen (wegen dem max in $m_{\mathcal{C}}(N)$) !

Seien $x_1, \dots, x_N \in [0, 1]$ beliebig, alle paarweise verschieden, so ist $m_{\mathcal{C}}(x_1, \dots, x_N) = 2N$, denn: Wähle

$$f_{1j}(x) = \mathbb{1}_{\{x < x_j\}} - \mathbb{1}_{\{x \geq x_j\}}, \quad f_{2j}(x) = -\mathbb{1}_{\{x < x_j\}} + \mathbb{1}_{\{x \geq x_j\}}.$$

Dann erzeugen alle $2N$ Entscheidungsregeln f_{1j}, f_{2j} jeweils verschiedene Labelings von x_1, \dots, x_N (Anschaulich: Lege senkrechte Gerade jeweils genau an einen Punkt x_j an; links davon alles Klasse 1, rechts davon alles Klasse -1 und umgekehrt).

Alle anderen Baumstumpf-Entscheidungsregeln erzeugen keine weiteren Labelings.

Gibt es Indizes $i, j \in \{1, \dots, N\}$ mit $x_i = x_j$, so gilt $m_{\mathcal{C}}(x_1, \dots, x_N) \leq 2N$ (klar).

$$\Rightarrow m_{\mathcal{C}}(N) = 2N.$$

(c) In d Dimensionen: Für $x^{(1)}, \dots, x^{(N)} \in [0, 1]^d$ paarweise verschieden wähle

$$f_{1jk}(x) = \mathbb{1}_{\{x < x_j^{(k)}\}} - \mathbb{1}_{\{x \geq x_j^{(k)}\}}, \quad f_{2jk}(x) = -\mathbb{1}_{\{x < x_j^{(k)}\}} + \mathbb{1}_{\{x \geq x_j^{(k)}\}}, \quad j = 1, \dots, d, k = 1, \dots, N.$$

Alle anderen Baumstumpf-Entscheidungsregeln erzeugen keine weiteren Labelings (nicht total trivial, aber in Bild offensichtlich!).

Gibt es Indizes $i, j \in \{1, \dots, N\}$ mit $x_i = x_j$, so gibt es höchstens noch weniger verschiedene Labelings.

$\Rightarrow m_{\mathcal{C}}(x_1, \dots, x_N) \leq \min\{2Nd, 2^N\}$ (es kann höchstens 2^N Labelings geben, und durch f_{1jk}, f_{2jk} gibt es höchstens $2Nd$).

Für $m_{\mathcal{C}}(x_1, \dots, x_N) = \min\{2Nd, 2^N\}$ wäre also nur noch zu zeigen, dass $m_{\mathcal{C}}(x_1, \dots, x_N) \geq \min\{2Nd, 2^N\}$, d.h. es mindestens eine Verteilung von Punkten gibt, für welche alle f_{1jk}, f_{2jk} verschiedene Labelings erzeugen. Das kann man sich graphisch überlegen, ist aber mathematisch exakt etwas aufwendig.

(d) aus (c) \Rightarrow

$$\begin{aligned} m_{\mathcal{C}}(x_1, \dots, x_N) &\leq \min\{2Nd, 2^N\} \\ \Rightarrow \mathcal{V}(\mathcal{C}) &\leq \inf\{N \in \mathbb{N} : \min\{2Nd, 2^N\} < 2^N\} = \inf\{N \in \mathbb{N} : 2Nd < 2^N\}. \end{aligned}$$

Es gilt mit $N = 2 \log_2(2d)$:

$$2^N = (2d)^2 = 4d^2, \quad 2Nd = 4d \log_2(2d),$$

d.h. wegen $d > \log_2(2d)$ für $d \geq 2$ (Hinweis):

$$2^N > 2Nd.$$

$$\Rightarrow \mathcal{V}(\mathcal{C}) \leq N \stackrel{\mathcal{V}(\mathcal{C}) \in \mathbb{N}}{\Rightarrow} \mathcal{V}(\mathcal{C}) \leq \lfloor 2 \log_2(2d) \rfloor.$$

Aufgabe 2 (Beweis der Margin Condition, Lemma 6.27(ii))

Lösung:

(a) Es gilt $\mathbb{E}\tilde{L}(Y, \delta(X)) = \mathbb{E}[\mathbb{E}[\phi(-Y\delta(X))|X = x]]$, und

$$\mathbb{E}[\phi(-Y\delta(X))|X = x] = \phi(-\delta(x))\eta(x) + \phi(\delta(x))(1 - \eta(x)).$$

Punktweises Minimieren liefert $\delta^*(x) \in \operatorname{argmin}_{z \in \mathbb{R}} \Phi_{\eta(x)}(z)$ mit $\Phi_{\eta}(z) := \phi(-z)\eta + \phi(z)(1 - \eta)$.

ϕ differenzierbar $\Rightarrow z \mapsto \Phi_{\eta(x)}(z)$ differenzierbar und daher

$$0 = \Phi'_{\eta(x)}(\delta^*(x)).$$

Aufgefasst als Gleichung für $\delta^*(x)$ ist somit $\delta^*(x) = (\Phi'_{\eta(x)})^{-1}(0)$, d.h. setze $g(\eta) = (\Phi'_{\eta})^{-1}(0)$. Es gilt außerdem

$$0 = \Phi'_{\eta}(g(\eta)) = -\phi'(-g(\eta))\eta + \phi'(\eta)(1 - \eta), \quad (*)$$

dies liefert die Gleichung.

(b) Es gilt (bedingen auf X):

$$\begin{aligned} &\mathbb{E}[(\tilde{L}(Y, \delta(X)) - \tilde{L}(Y, \delta^*(X)))^2 | X = x] \\ &\stackrel{\delta^*(x) = g(\eta(x))}{=} \eta(x) [\phi(-\delta(x)) - \phi(-g(\eta(x)))]^2 + (1 - \eta(x)) [\phi(\delta(x)) - \phi(g(\eta(x)))]^2 \\ &=: A_2(\eta(x), \delta(x)), \end{aligned}$$

mit

$$A_2(\eta, \delta) := \eta \cdot [\phi(-\delta) - \phi(-g(\eta))]^2 + (1 - \eta) [\phi(\delta) - \phi(g(\eta))]^2.$$

und analog

$$\begin{aligned} &\mathbb{E}[\tilde{L}(Y, \delta(X)) - \tilde{L}(Y, \delta^*(X)) | X = x] \\ &= \eta(x) [\phi(-\delta(x)) - \phi(-g(\eta(x)))] + (1 - \eta(x)) [\phi(\delta(x)) - \phi(g(\eta(x)))] =: A_1(\eta(x), \delta(x)) \end{aligned}$$

mit

$$A_1(\eta, \delta) := \eta \cdot [\phi(-\delta) - \phi(-g(\eta))] + (1 - \eta) [\phi(\delta) - \phi(g(\eta))].$$

(c) Es gilt

$$\begin{aligned}\partial_\eta A_1(\eta, \delta) &= [\phi(-\delta) - \phi(-g(\eta))] - [\phi(\delta) - \phi(g(\eta))] \\ &\quad + [\eta\phi'(-g(\eta)) - (1-\eta)\phi'(g(\eta))] \cdot g'(\eta) \\ &\stackrel{(*)}{=} [\phi(-\delta) - \phi(-g(\eta))] - [\phi(\delta) - \phi(g(\eta))].\end{aligned}\tag{1}$$

(d) Außerdem

$$\begin{aligned}\partial_\eta A_2(\eta, \delta) &= [\phi(-\delta) - \phi(-g(\eta))]^2 - [\phi(\delta) - \phi(g(\eta))]^2 \\ &\quad + 2\{\eta\phi'(-g(\eta))[\phi(-\delta) - \phi(-g(\eta))] - (1-\eta)\phi'(g(\eta))[\phi(\delta) - \phi(g(\eta))]\}g'(\eta) \\ &= \underbrace{\{\phi(-\delta) - \phi(-g(\eta)) - \phi(\delta) + \phi(g(\eta))\}}_{=\partial_\eta A_1(\eta, \delta)} \\ &\quad \times \{\phi(\delta) - \phi(g(\eta)) + \phi(-\delta) - \phi(-g(\eta)) + \{\eta\phi'(-g(\eta)) + (1-\eta)\phi'(g(\eta))\}g'(\eta)\}. \\ &= \partial_\eta A_1(\eta, \delta) \cdot \{\phi(\delta) + \phi(-\delta) + B(\eta)\}\end{aligned}\tag{2}$$

Hier haben wir beim ersten Summanden 3. Binomische Formel genutzt $a^2 - b^2 = (a - b)(a + b)$, beim zweiten

$$\begin{aligned}&2\eta\phi'(-g(\eta))[\phi(-\delta) - \phi(-g(\eta))] - 2(1-\eta)\phi'(g(\eta))[\phi(\delta) - \phi(g(\eta))] \\ &= \underbrace{\eta\phi'(-g(\eta))}_{\stackrel{(*)}{=} (1-\eta)\phi'(g(\eta))} [\phi(-\delta) - \phi(-g(\eta))] - \underbrace{(1-\eta)\phi'(g(\eta))}_{\stackrel{(*)}{=} \eta\phi'(-g(\eta))} [\phi(\delta) - \phi(g(\eta))] \\ &\quad - (1-\eta)\phi'(g(\eta))[\phi(-\delta) - \phi(-g(\eta))] + \eta\phi'(-g(\eta))[\phi(\delta) - \phi(g(\eta))] \\ &= \{\eta\phi'(-g(\eta)) + (1-\eta)\phi'(g(\eta))\} \cdot \{\phi(-\delta) - \phi(-g(\eta)) - \phi(\delta) + \phi(g(\eta))\}.\end{aligned}$$

(e) Es gilt

$$\partial_\eta A_1(\eta, \delta) \begin{cases} \geq 0, & g(\eta) \geq \delta \\ \leq 0, & g(\eta) \leq \delta. \end{cases}$$

Falls $g(\eta) \geq \delta$, folgt also mit (d):

$$\begin{aligned}\partial_\eta A_2(\eta, \delta) &\leq \underbrace{\{\phi(\delta) + \phi(-\delta) + B(\eta)\}}_{\leq \phi(\rho) + \phi(-\rho)} \cdot \underbrace{\partial_\eta A_1(\eta, \delta)}_{\geq 0} \\ &\leq \{\phi(\rho) + \phi(-\rho) + C_\phi\} \cdot \partial_\eta A_1(\eta, \delta).\end{aligned}$$

Falls $g(\eta) \leq \delta$, gilt die umgekehrte Ungleichung wegen $\partial_\eta A_1(\eta, \delta) \leq 0$.

Die Ungleichung $\phi(\delta) + \phi(-\delta) \leq \phi(\rho) + \phi(-\rho)$ folgt aus der Konvexität von ϕ ($\Rightarrow \phi'$ monoton wachsend): Es ist

$$\frac{\phi(-\delta) - \phi(-\rho)}{\rho - \delta} \leq \phi'(-\delta) \leq \phi'(\delta) \leq \frac{\phi(\rho) - \phi(\delta)}{\rho - \delta}.$$

(f) Trivial. Es tritt jeweils in $A_1(g^{-1}(\delta), \delta)$ und $A_2(g^{-1}(\delta), \delta)$ auf:

$$\phi(-\delta) - \phi(-g(g^{-1}(\delta))) = 0 \quad \text{bzw.} \quad \phi(\delta) - \phi(g(g^{-1}(\delta))) = 0.$$

(g) Integration \Rightarrow Für $g(\eta) \geq \delta$:

$$\begin{aligned} A_2(\eta, \delta) &= \int_{g^{-1}(\delta)}^{\eta} \partial_{\eta} A_2(s, \delta) ds \stackrel{(e)}{\leq} \{\phi(\rho) + \phi(-\rho) + C_{\phi}\} \cdot \int_{g^{-1}(\delta)}^{\eta} \partial_{\eta} A_1(s, \delta) ds \\ &\leq \{\phi(\rho) + \phi(-\rho) + C_{\phi}\} A_1(\eta, \delta). \end{aligned}$$

Für $g(\eta) \leq \delta$ nutze $A_2(\eta, \delta) = \int_{g^{-1}(\delta)}^{\eta} \partial_{\eta} A_2(s, \delta) ds = - \int_{\eta}^{g^{-1}(\delta)} \partial_{\eta} A_2(s, \delta) ds$.

(h) Bestimmung von C_{ϕ} :

- Falls $\phi(x) = e^x$: $g(\eta) = \frac{1}{2} \log(\frac{\eta}{1-\eta}) \Rightarrow g'(\eta) = \frac{1}{2}(\frac{1}{\eta} + \frac{1}{1-\eta}) = \frac{1}{2\eta(1-\eta)}$. Außerdem

$$\phi'(g(\eta)) = \eta^{1/2}(1-\eta)^{-1/2}, \quad \phi'(-g(\eta)) = \eta^{-1/2}(1-\eta)^{1/2}.$$

Einsetzen:

$$\begin{aligned} C_{\phi} &= 0 \vee \max_{\eta} \left\{ \frac{2(\eta(1-\eta))^{1/2}}{2\eta(1-\eta)} - \eta^{1/2}(1-\eta)^{-1/2} - \eta^{-1/2}(1-\eta)^{1/2} \right\} \\ &= 0 \vee \max_{\eta} \left\{ \eta^{-1/2}(1-\eta)^{-1/2} - \eta^{1/2}(1-\eta)^{-1/2} - \eta^{-1/2}(1-\eta)^{1/2} \right\} = 0. \end{aligned}$$

- Falls $\phi(x) = \log(1+e^x)$: $g(\eta) = \log(\frac{\eta}{1-\eta}) \Rightarrow g'(\eta) = \frac{1}{\eta(1-\eta)}$. Außerdem

$$\phi'(x) = \frac{e^x}{1+e^x}, \quad \phi'(g(\eta)) = \eta, \quad \phi'(-g(\eta)) = 1-\eta.$$

Einsetzen:

$$C_{\phi} = 0 \vee \max_{\eta} \left\{ \frac{2\eta(1-\eta)}{\eta(1-\eta)} + \log(\eta(1-\eta)) \right\} = \max_{\eta} \left\{ 2 + \underbrace{\log(\eta(1-\eta))}_{\leq 4^{-1}} \right\} = 2 - 2 \log(2).$$

Aufgabe 3 (Beweis Lemma 6.31 / Covering Numbers übertragen)

Lösung: Wir müssen in den Schritten (a)-(d) jeweils zeigen, dass ein $\tilde{\varepsilon}$ -Covering der rechten Seite jeweils auch ein ε -Covering der linken Seite liefert. Wir geben jeweils an, wie die Coverings der linken Seite aus denen der rechten Seite konstruiert werden.

- (a) Ist (\tilde{f}_j) ein ε -Covering von \mathcal{F}_1 , so ist $f_j(x, y) := \tilde{f}_j(x, y) - \tilde{L}(y, \delta_0(x))$ ein ε -Covering von \mathcal{F} , denn:

Ist $f \in \mathcal{F}$ beliebig, so kann f geschrieben werden als $f = \tilde{f} - \tilde{L}(y, \delta_0(x))$ mit $\tilde{f} \in \mathcal{F}_1$. Sei j mit $\|\tilde{f} - \tilde{f}_j\|_{2,n} \leq \varepsilon$. Dann gilt:

$$\|f - f_j\|_{2,n} = \|\tilde{f} - \tilde{f}_j\|_{2,n} \leq \varepsilon.$$

$$\Rightarrow N(\varepsilon, \mathcal{F}, \|\cdot\|_{2,n}) \leq N(\varepsilon, \mathcal{F}_1, \|\cdot\|_{2,n}).$$

- (b) Ist (\tilde{f}_j) ein ε -Covering von \mathcal{F}_2 , so ist $f_j := \phi \circ \tilde{f}_j$ ein $\varepsilon \cdot \phi'(\rho)$ -Covering von \mathcal{F}_1 , denn:
Für $f \in \mathcal{F}_1$ gibt es $\tilde{f} \in \mathcal{F}_2$ mit $f = \phi \circ \tilde{f}$. Sei j mit $\|\tilde{f} - \tilde{f}_j\|_{2,n} \leq \varepsilon$. Dann gilt

$$\begin{aligned} \|f - f_j\|_{2,n} &= \left(\frac{1}{n} \sum_{i=1}^n \{\phi(\tilde{f}(X_i, Y_i)) - \phi(\tilde{f}_j(X_i, Y_i))\}^2 \right)^{1/2} \\ &\leq \phi'(\rho) \cdot \left(\frac{1}{n} \sum_{i=1}^n \{\tilde{f}(X_i, Y_i) - \tilde{f}_j(X_i, Y_i)\}^2 \right)^{1/2} = \phi'(\rho) \|\tilde{f} - \tilde{f}_j\|_{2,n} \leq \phi'(\rho) \varepsilon. \end{aligned}$$

denn ϕ ist auf $[-\rho, \rho]$ Lipschitz-stetig mit Konstante $\phi'(\rho)$.

Umstellen $\Rightarrow N(\varepsilon, \mathcal{F}_1, \|\cdot\|_{2,n}) \leq N(\frac{\varepsilon}{\phi'(\rho)}, \mathcal{F}_2, \|\cdot\|_{2,n})$.

(c) Ist (δ_j) ein ε -Covering von \mathcal{F}_3 bzgl. $\|\cdot\|_{2,n,X}$, so ist $f_j(x, y) = y\delta_j(x)$ ein ε -Covering von \mathcal{F}_2 bzgl. $\|\cdot\|_{2,n}$, denn:

Für $f \in \mathcal{F}_2$ gibt es $\delta \in \mathcal{F}_3$ mit $f(x, y) = y\delta(x)$. Sei j mit $\|\delta - \delta_j\|_{2,n,X} \leq \varepsilon$. Dann gilt

$$\|f - f_j\|_{2,n} = \left(\frac{1}{n} \sum_{i=1}^n \underbrace{\{Y_i\delta(X_i) - Y_i\delta_j(X_i)\}^2}_{=Y_i^2(\delta(X_i) - \delta_j(X_i))^2} \right)^{1/2} \stackrel{Y_i \in \{-1,1\}}{\leq} \|\delta - \delta_j\|_{2,n,X} \leq \varepsilon.$$

$$\Rightarrow N(\varepsilon, \mathcal{F}_2, \|\cdot\|_{2,n}) \leq N(\varepsilon, \mathcal{F}_3, \|\cdot\|_{2,n,X}).$$

(d) Ist (\tilde{f}_j) ein ε -Covering von \mathcal{F}_4 , so ist $f_j := \rho \cdot \tilde{f}_j$ ein $\rho\varepsilon$ -Covering von \mathcal{F}_3 , denn: Analog zu (b) mit $\phi(x) = \rho \cdot x$.

Homepage der Vorlesung:

<https://ssp.math.uni-heidelberg.de/sam-ws2020/>