



12. Übungsblatt

Aufgabe 1 (Maximalungleichungen aus der Bernstein-Ungleichung, Lemma 7.10(ii)):

Lösung:

(a) Es gilt für beliebiges $t_0 > 0$:

$$\begin{aligned} \mathbb{E}[W^2] &= \int_0^\infty \mathbb{P}(W^2 \geq u) du = \int_0^\infty \mathbb{P}(W \geq \sqrt{u}) du \stackrel{t=\sqrt{u}}{=} 2 \int_0^\infty t \mathbb{P}(W \geq t) dt \\ &= \underbrace{2 \int_0^{t_0} t \mathbb{P}(W \geq t) dt}_{\leq t_0^2} + 2 \int_{t_0}^\infty t \mathbb{P}(W \geq t) dt. \end{aligned}$$

(b) Es gilt für jedes $g \in \mathcal{G}$:

$$\|\tilde{g}\|_\infty \leq \frac{\|g\|_\infty}{M\sqrt{\frac{H}{n}}} \leq \sqrt{\frac{n}{H}},$$

und

$$\mathbb{E}[g(Z_1)^2] = \frac{\mathbb{E}[g(Z_1)^2]}{\mathbb{E}[g(Z_1)^2]} \leq 1.$$

Mit Bernstein-Ungleichung gilt

$$\begin{aligned} \mathbb{P}\left(\left|\sum_{i=1}^n \{\tilde{g}(Z_i) - \mathbb{E}\tilde{g}(Z_i)\}\right| \geq t\right) &\leq 2 \exp\left(-\frac{t^2}{2n + \frac{2}{3}\sqrt{\frac{n}{H}} \cdot t}\right) \\ &\stackrel{t \geq 3\sqrt{nH}}{\leq} 2 \exp\left(-\frac{t^2}{\frac{4}{3}\sqrt{\frac{n}{H}} \cdot t}\right) = 2 \exp\left(-\frac{3t}{4\sqrt{\frac{n}{H}}}\right). \end{aligned}$$

Damit folgt

$$\mathbb{P}(W \geq t) \leq |\mathcal{G}| \mathbb{P}\left(\left|\sum_{i=1}^n \{\tilde{g}(Z_i) - \mathbb{E}\tilde{g}(Z_i)\}\right| \geq t\right) \leq 2|\mathcal{G}| \exp\left(-\frac{3t}{4\sqrt{\frac{n}{H}}}\right).$$

(c) Wähle $t_0 = 3\sqrt{nH}$ und $a = \frac{3}{4}\sqrt{\frac{H}{n}}$.

Partielle Integration $\Rightarrow \int t e^{-at} dt = -(a^{-2} + a^{-1}t)e^{-at} \Rightarrow \int_{t_0}^\infty t e^{-at} dt = (a^{-2} + a^{-1}t_0)e^{-at_0}$.

Es folgt

$$\begin{aligned} 2 \cdot \int_{t_0}^\infty t \mathbb{P}(W \geq t) dt &\leq 4(a^{-2} + a^{-1}t_0)|\mathcal{G}| \underbrace{e^{-at_0}}_{=e^{-\frac{9}{4}H} \leq |\mathcal{G}|^{-1}} \\ &\leq 4\left\{\left(\frac{4}{3}\right)^2 \frac{n}{H} + 4n\right\} \\ &\stackrel{|\mathcal{G}| \geq 2}{\leq} 24n. \end{aligned}$$

Zusammen mit $t_0^2 = 9nH$ folgt aus (a) die Behauptung.

Aufgabe 2 (Maximalungleichung für Normalverteilungen, Lemma 7.11):

Lösung:

(a) $Z_1, \dots, Z_n \sim N(0, v^2)$ i.i.d. \Rightarrow

$$W_j = \frac{1}{v\sqrt{n}} \frac{\sum_{i=1}^n a_{ij} Z_i}{\left(\frac{1}{n} \sum_{i=1}^n a_{ij}^2\right)^{1/2}} \sim N(0, 1).$$

(b) Für $W_j \sim N(0, 1)$ gilt $\mathbb{E} \exp\left(\frac{W_j^2}{4}\right) = \sqrt{2}$. Mit der konvexen, monoton wachsenden Funktion $\varphi_2(x) = \exp(x^2) - 1$ folgt

$$\varphi_2\left(\mathbb{E} \max_{j=1, \dots, N} \frac{|W_j|}{2}\right) \leq \mathbb{E} \max_{j=1, \dots, N} \varphi_2\left(\frac{|W_j|}{2}\right) \leq \sum_{j=1}^N \mathbb{E} \varphi_2\left(\frac{|W_j|}{2}\right) \leq N \cdot (\sqrt{2} - 1) \leq N.$$

\Rightarrow

$$\mathbb{E} \max_{j=1, \dots, N} |W_j| \leq 2\varphi_2^{-1}(N) = 2\sqrt{\log(N+1)}.$$

(c) Mit $\varphi_1(x) = e^x - 1$:

$$\varphi_1\left(\mathbb{E} \max_{j=1, \dots, N} \frac{|W_j|^2}{4}\right) \leq \mathbb{E} \max_{j=1, \dots, N} \varphi_1\left(\frac{|W_j|^2}{4}\right) \leq \sum_{j=1}^N \mathbb{E} \varphi_1\left(\frac{|W_j|^2}{4}\right) \leq N \cdot (\sqrt{2} - 1) \leq N.$$

\Rightarrow

$$\mathbb{E} \max_{j=1, \dots, N} |W_j|^2 \leq 4\varphi_1^{-1}(N) = 4 \log(N+1).$$

Aufgabe 3 (Covering Numbers von neuronalen Netzwerken, Lemma 7.12):

Lösung:

(a) Schreibe $\theta = (v^1, \dots, v^L, W^{(0)}, \dots, W^{(L)})$ (Matrizen zeilenweise) als Vektor. Dann gilt $\theta \in [-1, 1]^T$ mit

$$T = \sum_{l=1}^L \text{Anz. Einträge } v^{(l)} + \sum_{l=0}^L \text{Anz. Einträge } W^{(l)} = \sum_{l=1}^L p_l + \sum_{l=0}^L p_l p_{l+1}.$$

(b) Für jedes $f_\theta \in \mathcal{F}(L, p, s, \infty)$ sind jeweils höchstens s Einträge von θ Nicht Null, d.h. $\mathcal{F}(L, p, s, \infty) = \{f_\theta : \theta \in \Theta\}$ mit

$$\begin{aligned} \Theta &\subset \{\theta \in [-1, 1]^T : \leq s \text{ Einträge von } \theta \text{ nicht Null}\} \\ &= \{\theta \in [-1, 1]^T : \exists S \subset \{1, \dots, T\}, |S| \leq s : \forall j \in S^c : \theta_j = 0\} \\ &= \bigcup_{S \subset \{1, \dots, T\} : |S| \leq s} \underbrace{\{\theta \in [-1, 1]^T : \forall j \in S^c : \theta_j = 0\}}_{=: \Theta_S}. \end{aligned}$$

(c) Wir wählen eine geeignete Gitterapproximation von Θ_S . OBdA. sei $S = \{1, \dots, s\}$ (damit $\Theta_S \subset [-1, 1]^s \times \{0\}^{T-s}$). Dann setze

$$\tilde{\Theta}_S = \left\{ -1 + j \cdot a : j = 1, \dots, m \right\}^s \times \{0\}^{T-s}.$$

Falls $-1 + m \cdot a \geq 1 - a$, erfüllt $\tilde{\Theta}_S$ die Approximationsaussage. Dies ist erfüllt mit $(m+1) \cdot a \geq 2$, d.h. $m \geq \frac{2}{a} - 1$ bzw. falls $m \geq \lfloor \frac{2}{a} \rfloor$.

Es folgt

$$|\tilde{\Theta}_S| \leq m^s = \left\lfloor \frac{2}{a} \right\rfloor^s.$$

(d) Es gilt

$$\begin{aligned} |\tilde{\Theta}| &\leq \sum_{S \subset \{1, \dots, T\}: |S| \leq s} |\tilde{\Theta}_S| \leq \sum_{k=0}^s \sum_{S \subset \{1, \dots, T\}: |S|=k} |\tilde{\Theta}_S| \\ &\stackrel{(c)}{=} \sum_{k=0}^s \#\{S \subset \{1, \dots, T\} : |S| = k\} \cdot \left[\frac{2}{a}\right]^s. \end{aligned}$$

Es gilt

$$\#\{S \subset \{1, \dots, T\} : |S| = k\} = \binom{T}{k} \leq T^k \leq V^k,$$

denn

$$T = \sum_{l=0}^L p_l p_{l+1} + \sum_{l=1}^L p_l \leq \sum_{l=0}^L (p_l + 1) p_{l+1} \leq \prod_{l=0}^{L+1} (p_l + 1) = V.$$

Einsetzen:

$$|\tilde{\Theta}| \leq \sum_{k=0}^s V^k \cdot \left(\frac{2}{a}\right)^k \leq \left(\frac{2V}{a}\right)^{s+1}.$$

(e) Für $\gamma > 0$ wähle $a = \frac{\gamma}{(L+1)V}$. Dann gibt es für jedes $f \in \mathcal{F}(L, p, s, F)$ ein $f_{\tilde{\theta}}$ mit $\tilde{\theta} \in \tilde{\Theta}$, so dass

$$\|f_{\theta} - f_{\tilde{\theta}}\|_{\infty} \leq a \cdot (L+1) \cdot V \leq \gamma.$$

\Rightarrow

$$N(\gamma, \mathcal{F}(L, p, s, F), \|\cdot\|_{\infty}) \leq \left(\frac{2V}{a}\right)^{s+1} = (2\gamma^{-1}V^2(L+1))^{s+1}.$$

(f) Es gilt

$$\begin{aligned} |A_{\theta}^{k-}(x) - A_{\theta}^{k-}(x')| &\leq \|W^{(L)}\|_Z \cdot \dots \cdot \|W^{(k-1)}\|_Z \|x - x'\|_{\infty} \\ &\stackrel{\|W^{(l)}\|_{\infty} \leq 1, W^{(l)} \in \mathbb{R}^{p_l \times p_{l+1}}}{\leq} \left(\prod_{l=k-1}^L p_l\right) \cdot \|x - x'\|_{\infty}. \end{aligned}$$

(g) Es gilt

$$\begin{aligned} |A_{\theta}^{k+}(x)|_{\infty} &\leq \|W^{(k)}\|_Z \cdot \left\{ \dots \|W^{(1)}\|_Z \left\{ \|W^{(0)}\|_Z \|x\|_{\infty} + \|v^{(1)}\|_{\infty} \right\} \dots \right\} + \|v^{(k)}\|_{\infty} \\ &\leq \prod_{l=0}^{k-1} (p_l + 1). \end{aligned}$$

(h) Es gilt mit $\sigma_{v^{(L+1)}}(x) := x$:

$$\begin{aligned}
|f(x) - f_{\tilde{\theta}}(x)| &\leq \sum_{k=1}^{L+1} \left| A_{\theta}^{(k+1)-} \circ \sigma_{v^{(k)}} W^{(k-1)} A_{\tilde{\theta}}^{(k-1)-}(x) - A_{\theta}^{(k+1)-} \circ \sigma_{\tilde{v}^{(k)}} \tilde{W}^{(k-1)} A_{\tilde{\theta}}^{(k-1)-}(x) \right| \\
&\stackrel{(f)}{\leq} \sum_{k=1}^{L+1} \left(\prod_{l=k}^L p_l \right) \left\| \sigma_{v^{(k)}} W^{(k-1)} A_{\tilde{\theta}}^{(k-1)-}(x) - \sigma_{\tilde{v}^{(k)}} \tilde{W}^{(k-1)} A_{\tilde{\theta}}^{(k-1)-}(x) \right\|_{\infty} \\
&\leq \sum_{k=1}^{L+1} \left(\prod_{l=k}^L p_l \right) \cdot [\|v^{(k)} - \tilde{v}^{(k)}\|_{\infty} + \|W^{(k-1)} - \tilde{W}^{(k-1)}\|_Z \cdot \|A_{\tilde{\theta}}^{(k-1)-}(x)\|_{\infty}] \\
&\stackrel{(g)}{\leq} \sum_{k=1}^{L+1} \left(\prod_{l=k}^L p_l \right) \cdot \left[a + p_{k-1} \cdot a \cdot \prod_{l=0}^{k-2} (p_l + 1) \right] \\
&\leq a \cdot (L+1) \cdot \prod_{l=0}^L (p_l + 1) = a \cdot (L+1) \cdot V.
\end{aligned}$$

(i) Ist $f \in \mathcal{F}(L, p, s, F)$, so gilt für jeden Layer $l \in \{1, \dots, L\}$: Höchstens s Spalten von $W^{(l)} \in \mathbb{R}^{p_l \times p_{l+1}}$ sind keine kompletten Nullspalten. Ist aber die j -te Spalte von $W^{(l)}$ eine komplette Nullspalte, kann diese zusammen mit der j -ten Zeile von $W^{(l-1)}$ und dem j -ten Eintrag aus $v^{(l)}$ aus dem Modell entfernt werden, und es wird immer noch dieselbe Funktion dargestellt. Daher gilt in diesem Fall

$$f \in \mathcal{F}(L, (p_0, p_1, \dots, p_{l-1}, p_l - 1, p_{l+1}, \dots, p_L, p_{L+1}), s, F).$$

Iteration dieses Vorgehens liefert

$$f \in \mathcal{F}(L, (p_0, p_1 \wedge s, \dots, p_L \wedge s, p_{L+1}), s, F).$$

(j) Mit $\tilde{V} = (p_0 + 1) \cdot (p_{L+1} + 1) \cdot \prod_{l=1}^L ((p_l \wedge s) + 1) \leq 2^{L+2} p_0 p_{L+1} s^L$ folgt:

$$\begin{aligned}
H(\gamma) &= \log N(\gamma, \mathcal{F}(L, p, s, F), \|\cdot\|_{\infty}) \\
&\stackrel{(i)}{=} \log N(\gamma, \mathcal{F}(L, (p_0, p_1 \wedge s, \dots, p_L \wedge s, p_{L+1}), s, F), \|\cdot\|_{\infty}) \\
&\stackrel{(e)}{\leq} (s+1) \log(2\gamma^{-1} \tilde{V}^2 (L+1)) \\
&= (s+1) \log(2^{2L+5} \gamma^{-1} (L+1) p_0^2 p_{L+1}^2 s^{2L}) \\
&\leq 2s \cdot \{(2L+5) \log(2) + \log(\gamma^{-1}) + \log(2L) + 2 \log(p_0 p_{L+1}) + 2L \log(s)\} \\
&\leq c \cdot s \cdot \{L \log(s) + \log(\gamma^{-1}) + \log(p_0 p_{L+1})\}
\end{aligned}$$

mit $c \geq 1$ eine universelle Konstante, groß genug und $s \geq 2, L \geq 1$.

Homepage der Vorlesung:

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