



## 5. Übungsblatt

### Aufgabe 1 (Beispiel 4.1: Naiver Klassifizierer)

#### Lösung:

- (a) Es gilt wegen  $y \in \{+1, -1\}$ :

$$\tilde{L}(y, s) = (y - s)^2 = y^2 - 2ys + s^2 = 1 - 2ys + (ys)^2 = (1 - ys)^2 = \phi(-ys)$$

mit  $\phi(x) = (1 + x)^2$ .

- (b) Es ist  $\Phi_\eta(z) = \phi(-z)\eta + \phi(z)(1 - \eta) = (1 - z)^2\eta + (1 + z)^2(1 - \eta)$ .  
 Suche Minimierer von  $z \mapsto \Phi_\eta(z)$ :

$$0 = \Phi'_\eta(z) = -2(1 - z)\eta + 2(1 + z)(1 - \eta) = 2 + 2z - 4\eta \quad \Rightarrow \quad z = 2\eta - 1.$$

Satz 3.19  $\Rightarrow \delta^*(x) = 2\eta(x) - 1$  mit  $\eta(x) = \mathbb{P}(Y = 1|X = x)$ .

- (c) Es gilt  $\delta^*(x) > 0 \iff \eta(x) > \frac{1}{2} \iff f^*(x) = \operatorname{argmax}_{k \in \{+1, -1\}} \mathbb{P}(Y = k|X = x) = 1$ .  
 $\Rightarrow f^*(x) = \operatorname{sign}(\delta^*(x))$   
 $\Rightarrow$  Kalibrierungsbedingung ist erfüllt.

- (d)  $\delta^* \in \Delta$  ist äquivalent zu  $\forall x \in \mathcal{X} : 2\eta(x) - 1 = \delta^*(x) = x^T \beta^*$  für ein  $\beta^* \in \mathbb{R}^d$ , d.h. es müsste gelten

$$\eta(x) = \frac{1}{2} + \frac{1}{2}x^T \beta^*.$$

Da die linke Seite  $\in [0, 1]$  ist, kann dies nur gelten, wenn  $\mathcal{X}$  beschränkt ist.

- (e) Schon in (b) gesehen:  $g(\eta) = \operatorname{argmin}_{z \in \mathbb{R}} \Phi_\eta(z) = 2\eta - 1$ .  
 Außerdem

$$H(\eta) = \Phi_\eta(g(\eta)) = (2 - 2\eta)^2\eta + (2\eta)^2(1 - \eta) = 4\eta(1 - \eta).$$

Damit ist

$$1 - H(\eta) = 1 - 4\eta + 4\eta^2 = 4\left(\eta - \frac{1}{2}\right)^2 \quad \Rightarrow \quad \left(\frac{1}{2}\right)^2(1 - H(\eta)) = \left(\eta - \frac{1}{2}\right)^2.$$

Außerdem  $\phi(0) = 1$ ,  $\phi$  konvex. Satz 3.21  $\Rightarrow$  Mit  $s = 2$ ,  $C_H = \frac{1}{2}$  gilt die Risikoübertragungsformel mit

$$G(r) = 2C_H r^{1/s} = r^{1/2}.$$

- (f) Fall  $q \in [0, \infty)$ :  $G(r) = 4C_H^{\frac{s(q+1)}{q+s}} C^{-\frac{1}{q+s}} r^{\frac{q+1}{q+s}} = 4\left(\frac{1}{2}\right)^{\frac{2(q+1)}{q+2}} C^{-\frac{1}{q+2}} r^{\frac{q+1}{q+2}}$ .  
 Fall  $q = \infty$ :  $G(r) = 2\frac{C_H^s}{c^{s-1}} r = \frac{1}{2c} \cdot r$ .

(g) Es gilt wegen  $\frac{1}{2}X^T\beta^* \sim N(\frac{1}{2}\mu^T\beta^*, \frac{1}{4}\|\beta^*\|_2^2) = N(0, 1)$ :

$$\begin{aligned} \mathbb{P}(|\eta(X) - \frac{1}{2}| \leq t) &= \mathbb{P}(\frac{1}{2}|X^T\beta^*| \leq t) \stackrel{Z \sim N(0,1)}{=} \mathbb{P}(|Z| \leq t) = 2\Phi(t) - 1 \\ &\stackrel{\text{Hinweis}}{\leq} 2\Phi'(0)t = \sqrt{\frac{2}{\pi}} \cdot t. \end{aligned}$$

Hier ist  $\Phi(x) = \int_{-\infty}^x \frac{1}{\sqrt{2\pi}} \exp(-y^2/2) dy$  und damit  $\Phi'(x) = \frac{1}{\sqrt{2\pi}} \exp(-x^2/2)$ .  
Damit ist die Rauschbedingung

$$\mathbb{P}(|\eta(X) - \frac{1}{2}| \leq t) \leq Ct^q \quad \forall t > 0$$

erfüllt mit  $C = \sqrt{\frac{2}{\pi}}$ ,  $q = 1$ .

Aufgabe 2 (Nachprüfen: Kalibrierungsbedingung und Risiko-Übertragungsformel)

**Lösung:** Für  $\phi(x) = e^x$ :

- (a)  $\phi'(x) = e^x > 0 \Rightarrow \phi$  monoton wachsend,  
 $\phi''(x) > 0 \Rightarrow \phi$  konvex,  
 $\phi(0) = e^0 = 1$ .

- (b) Es ist  $\Phi_\eta(z) = \phi(-z)\eta + \phi(z)(1-\eta) = e^{-z}\eta + e^z(1-\eta)$ . Suche Minimierer von  $z \mapsto \Phi_\eta(z)$ :

$$0 = \Phi'_\eta(z) = -e^{-z}\eta + e^z(1-\eta) \quad \Rightarrow \quad z = \frac{1}{2} \log\left(\frac{\eta}{1-\eta}\right).$$

Satz 3.19  $\Rightarrow \delta^*(x) = \frac{1}{2} \log\left(\frac{\eta(x)}{1-\eta(x)}\right)$  mit  $\eta(x) = \mathbb{P}(Y = 1|X = x)$ .

- (c) Es gilt  $\delta^*(x) = \frac{1}{2} \log\left(\frac{\eta(x)}{1-\eta(x)}\right) > 0 \iff \frac{\eta(x)}{1-\eta(x)} > 1 \iff \eta(x) > \frac{1}{2} \iff f^*(x) = \operatorname{argmax}_{k \in \{+1, -1\}} \mathbb{P}(Y = k|X = x) = 1$ .  
 $\Rightarrow f^*(x) = \operatorname{sign}(\delta^*(x))$   
 $\Rightarrow$  Kalibrierungsbedingung ist erfüllt.

- (d) Schon in (b) gesehen:  $g(\eta) = \operatorname{argmin}_{z \in \mathbb{R}} \Phi_\eta(z) = \frac{1}{2} \log\left(\frac{\eta}{1-\eta}\right)$ .  
Außerdem

$$\begin{aligned} H(\eta) &= \Phi_\eta(g(\eta)) = \exp\left(-\frac{1}{2} \log\left(\frac{\eta}{1-\eta}\right)\right)\eta + \exp\left(\frac{1}{2} \log\left(\frac{\eta}{1-\eta}\right)\right)(1-\eta) \\ &= \left(\frac{\eta}{1-\eta}\right)^{-1/2} \eta + \left(\frac{\eta}{1-\eta}\right)^{1/2} (1-\eta) \\ &= 2(1-\eta)^{1/2}\eta^{1/2} = 2((1-\eta)\eta)^{1/2}. \end{aligned}$$

Damit ist

$$p(\eta) := 1 - H(\eta) = 1 - 2((1-\eta)\eta)^{1/2}.$$

Es gilt  $p'(\eta) = 2(\eta - \frac{1}{2}) \cdot (\eta(1-\eta))^{-1/2}$ ,  $p''(\eta) = \frac{1}{2}(\eta(1-\eta))^{-3/2} \geq \frac{1}{2}(\frac{1}{4})^{-3/2} = 4$ .  
Taylor-Entwicklung um  $\eta = \frac{1}{2}$ :

$$1 - H(\eta) = p(\eta) = p\left(\frac{1}{2}\right) + \left(\eta - \frac{1}{2}\right)p'\left(\frac{1}{2}\right) + \frac{1}{2}\left(\eta - \frac{1}{2}\right)^2 p''(\xi) \geq \frac{1}{2}\left(\eta - \frac{1}{2}\right)^2 \cdot 4 = 2\left(\eta - \frac{1}{2}\right)^2.$$

Außerdem  $\phi(0) = 1$ ,  $\phi$  konvex. Satz 3.21  $\Rightarrow$  Mit  $s = 2$ ,  $C_H = \frac{1}{\sqrt{2}}$  gilt die Risikoübertragungsformel mit

$$G(r) = 2C_H r^{1/s} = \sqrt{2}r^{1/2}.$$

Für  $\phi(x) = \max\{1+x, 0\}$ :

- (a)  $1+x, 0$  monoton wachsend  $\Rightarrow \phi(x) = \max\{1+x, 0\}$  monoton wachsend (Maximum erhält Monotonie).  
 $1+x, 0$  konvex  $\Rightarrow \phi(x) = \max\{1+x, 0\}$  konvex (Maximum erhält Konvexität).  
 $\phi(0) = \max\{1, 0\} = 1$ .

- (b) Es ist  $\Phi_\eta(z) = \phi(-z)\eta + \phi(z)(1-\eta) = \max\{1-z, 0\}\eta + \max\{1+z, 0\}(1-\eta)$ . Suche Minimierer von  $z \mapsto \Phi_\eta(z)$ .  
Für  $z < -1$  ist  $\Phi_\eta(z) = (1-z)\eta$  monoton fallend, für  $z > 1$  ist  $\Phi_\eta(z) = (1+z)(1-\eta)$  monoton wachsend.  $\Rightarrow$  Minimierer liegt in  $[-1, 1]$ .  
Für  $z \in [-1, 1]$  ist

$$\Phi_\eta(z) = (1-z)\eta + (1+z)(1-\eta) = 1 + 2z \cdot \left(\frac{1}{2} - \eta\right).$$

Für  $\eta > \frac{1}{2}$  wird dies minimal für  $z = 1$ , für  $\eta < \frac{1}{2}$  wird dies minimal für  $z = -1$ . Für  $\eta = \frac{1}{2}$  gibt es keinen eindeutigen Minimierer.  
 $\Rightarrow z = \text{sign}(\eta - \frac{1}{2})$  ist Minimierer  
Satz 3.19  $\Rightarrow \delta^*(x) = \text{sign}(\eta(x) - \frac{1}{2})$ .

- (c) Es gilt  $\delta^*(x) = \text{sign}(\eta(x) - \frac{1}{2}) = f^*(x)$ , insbesondere also  $\Rightarrow f^*(x) = \text{sign}(\delta^*(x))$   
 $\Rightarrow$  Kalibrierungsbedingung ist erfüllt.  
Besonderheit hier:  $\delta^*(x)$  selbst ist auch diskret mit Werten in  $\{-1, +1\}$ !

- (d) Schon in (b) gesehen:  $g(\eta) = \text{sign}(\eta - \frac{1}{2})$ .  
Außerdem

$$H(\eta) = \Phi_\eta(g(\eta)) = 1 + 2\text{sign}(\eta - \frac{1}{2}) \cdot \left(\frac{1}{2} - \eta\right) = 1 - 2|\eta - \frac{1}{2}|.$$

Damit ist

$$1 - H(\eta) = 2|\eta - \frac{1}{2}|.$$

Außerdem  $\phi(0) = 1$ ,  $\phi$  konvex. Satz 3.21  $\Rightarrow$  Mit  $s = 1$ ,  $C_H = \frac{1}{2}$  gilt die Risikoübertragungsformel mit

$$G(r) = 2C_H r^{1/s} = r.$$

Aufgabe 3 (Ermittlung des Wolfe-Duals und der Optimalitätsbedingungen der SVM)

**Lösung:**

- (a) Es ist

$$L(\theta, p) = \frac{1}{2}\|\beta\|_2^2 + C \sum_{i=1}^n \xi_i + \sum_{i=1}^n \alpha_i (1 - \xi_i - Y_i(X_i^T \beta + \beta_0)) - \sum_{i=1}^n \gamma_i \xi_i$$

Untersuche die drei Ableitungen:  $\nabla_\theta = (\nabla_\beta, \nabla_{\beta_0}, \nabla_\xi)$ :

$$\nabla_\beta L(\theta, p) = \beta - \sum_{i=1}^n \alpha_i Y_i X_i, \quad \nabla_{\beta_0} L(\theta, p) = \sum_{i=1}^n \alpha_i Y_i, \quad \nabla_{\xi_i} L(\theta, p) = C - \alpha_i - \gamma_i.$$

Damit folgt die Aussage, denn die Gleichungen  $\nabla_\theta L(\theta, p) = 0$  ergeben genau die angegebenen Gleichungen.

- (b) Wir setzen die Nebenbedingungen  $\nabla_{\theta}L(\theta, p) = 0$  in die Optimierungsfunktion  $L(\theta, p)$  ein und formen um. Dabei achten wir darauf, dass eventuelle Nebenbedingungen für  $\alpha$  mitgenommen werden. Es gilt

$$\begin{aligned}
L(\theta, p) &= \frac{1}{2}\|\beta\|_2^2 + C \sum_{i=1}^n \xi_i + \sum_{i=1}^n \alpha_i(1 - \xi_i - Y_i(X_i^T \beta + \beta_0)) - \sum_{i=1}^n \gamma_i \xi_i \\
&= \frac{1}{2}\|\beta\|_2^2 + \sum_{i=1}^n \alpha_i + \sum_{i=1}^n \xi_i \cdot \underbrace{(C - \alpha_i - \gamma_i)}_{=0} - \beta_0 \underbrace{\sum_{i=1}^n \alpha_i Y_i}_{=0} - \underbrace{\left(\sum_{i=1}^n \alpha_i Y_i X_i^T\right)}_{=\beta^T} \beta \\
\nabla_{\theta}L(\theta, p) \stackrel{=0}{=} & \frac{1}{2}\|\beta\|_2^2 + \sum_{i=1}^n \alpha_i - \|\beta\|_2^2 \\
&= \sum_{i=1}^n \alpha_i - \frac{1}{2}\|\beta\|_2^2 \\
&= \sum_{i=1}^n \alpha_i - \frac{1}{2}\left\|\sum_{i=1}^n \alpha_i Y_i X_i\right\|_2^2 \\
&= \underbrace{\sum_{i=1}^n \alpha_i}_{=\mathbb{1}^T \alpha} - \frac{1}{2} \underbrace{\sum_{i,j=1}^n \alpha_i \alpha_j X_i^T X_j Y_i Y_j}_{=\alpha^T Q \alpha} \\
&= \mathbb{1}^T \alpha - \frac{1}{2} \alpha^T Q \alpha.
\end{aligned}$$

Maximierer von  $L(\theta, p)$  ist Minimierer von  $-L(\theta, p)$ . Dies liefert die angegebene Optimierungsfunktion.

Nebenbedingungen an  $\alpha$ :

- $\nabla_{\beta_0}L(\theta, p) = 0$  ist äquivalent zu  $\mathbb{Y}^T \alpha = \sum_{i=1}^n \alpha_i Y_i = 0$ .
- $\nabla_{\beta}L(\theta, p) = \beta - \sum_{i=1}^n \alpha_i Y_i X_i = 0$  ist irrelevant, da  $\beta$  nicht mehr in der Optimierungsfunktion vorkommt.
- $\nabla_{\xi_i}L(\theta, p) = C - \alpha_i - \gamma_i = 0$  liefert  $\alpha_i = C - \gamma_i \leq C$ , da  $\gamma_i \geq 0$ . Daher erhält man die Nebenbedingung  $\alpha_i \leq C$ .

- (c) Optimalitätsbedingung  $\nabla_{\beta}L(\hat{\theta}, \hat{p}) = 0$  liefert  $\hat{\beta} = \sum_{i=1}^n \alpha_i Y_i X_i$ .

Wegen  $G(\hat{\theta}) \leq 0$ ,  $\hat{p} \geq 0$  ist

$$0 = G(\hat{\theta})^T \hat{p} = \sum_j G(\hat{\theta})_j \hat{p}_j \iff \forall j : G(\hat{\theta})_j \hat{p}_j = 0.$$

Insbesondere gilt für alle  $i = 1, \dots, n$ :

$$\hat{\gamma}_i \hat{\xi}_i = 0, \quad \hat{\alpha}_i(1 - \hat{\xi}_i - Y_i(X_i^T \hat{\beta} + \hat{\beta}_0)) = 0. \quad (*)$$

Es sei  $i \in \{1, \dots, n\}$  mit  $\hat{\alpha}_i \in (0, C)$ .

$$\Rightarrow 0 = \nabla_{\beta_0}L(\hat{\theta}, \hat{p}) = C - \hat{\alpha}_i - \hat{\gamma}_i \Rightarrow \hat{\gamma}_i = C - \hat{\alpha}_i > 0.$$

$$(*) \Rightarrow \hat{\xi}_i = 0$$

$$(*), \hat{\alpha}_i \neq 0 \Rightarrow 0 = 1 - \hat{\xi}_i - Y_i(X_i^T \hat{\beta} + \hat{\beta}_0) = 1 - Y_i(X_i^T \hat{\beta} + \hat{\beta}_0) \Rightarrow 0 = Y_i - Y_i^2(X_i^T \hat{\beta} + \hat{\beta}_0) = Y_i - X_i^T \hat{\beta} - \hat{\beta}_0$$

$$\Rightarrow \hat{\beta}_0 = Y_i - X_i^T \hat{\beta}.$$

**Homepage der Vorlesung:**

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