

## MUSTERERKENNUNG, 8. SEMINAR – DISKRIMINATIVES LERNEN+

**Aufgabe 1.** Man betrachte das folgende Wahrscheinlichkeitsmodell mit zwei Klassen. Gegeben sei die a-priori Wahrscheinlichkeitsverteilung der Klassen  $p(k)$ ,  $k = 1, 2$ . Die bedingten Wahrscheinlichkeitsverteilungen der Beobachtungen  $x \in \mathbb{R}$  sind

$$p(x|k) = \tau/2 \cdot \exp[-\tau|x - \mu_k|],$$

wobei der Parameter  $\tau > 0$  für beide Klassen gleich ist. Leiten Sie die Formel für die a-posteriori Wahrscheinlichkeitsverteilung  $p(k|x)$  ab.

*Hinweis:* Berücksichtigen Sie, dass die bedingten Wahrscheinlichkeitsverteilungen nicht überall differenzierbar sind. Somit muss man bei der Ableitung eine Fallunterscheidung machen.


**Aufgabe 2.** (siehe das vorige Übungsblatt). Die Merkmale eines Objektes, welches sich in zwei Zuständen  $k = 1, 2$  befinden kann, sind Vektoren  $x = (x_1, x_2) \in \mathbb{R}^2$ . Die Wahrscheinlichkeitsverteilung ist

$$\begin{aligned} p(k=1) &= p(k=2), \\ p(x|k=1) &= C \cdot \exp\left[-\frac{(x_1 - \mu_1)^2}{\sigma^2}\right], \\ p(x|k=2) &= C \cdot \exp\left[-\frac{(x_2 - \mu_2)^2}{\sigma^2}\right], \end{aligned}$$

mit den Parametern  $\mu = (\mu_1, \mu_2) \in \mathbb{R}^2$  und  $\sigma \in \mathbb{R}$ . Wie sieht die Klasse der Entscheidungsregeln für dieses Wahrscheinlichkeitsmodell aus? Bestimmen Sie die Vapnik-Chervonenkis Dimension dieser Klasse.

**Aufgabe 3.** Bestimmen Sie die Vapnik-Chervonenkis Dimension für die Entscheidungsregel, die im zweidimensionalen Raum ein achsenparalleles Rechteck bildet (siehe Skizze unten).

$$e(x) = \begin{cases} 1 & \text{wenn } x_l \leq x_1 \leq x_r \text{ und } x_b \leq x_2 \leq x_t \\ 2 & \text{sonst} \end{cases}$$



**Aufgabe 4.** (Generalized Linear Models). Man betrachte die folgende Verbundwahrscheinlichkeitsverteilung für Paare  $(x, y) \in \mathcal{X} \times \mathcal{Y}$ . Gegeben sei eine Abbildung  $\varphi : \mathcal{X} \times \mathcal{Y} \rightarrow \mathbb{R}^d$ , die jedem Paar  $(x, y)$  einen  $d$ -dimensionalen Vektor zuordnet. Die somit definierte Wahrscheinlichkeitsverteilung ist

$$p(x, y) = \frac{1}{Z} \exp(\langle \varphi(x, y), w \rangle)$$

( $\langle \cdot \rangle$  bezeichnet das Skalarprodukt) mit einem Parametervektor  $w \in \mathbb{R}^d$  und mit der Normierungskonstante

$$Z = \sum_{xy} \exp(\langle \varphi(x, y), w \rangle).$$

**a)** Zeigen Sie, dass die Gaussche Wahrscheinlichkeitsverteilung (Einfachheit halber für eine eindimensionale Zufallsvariable  $x \in \mathbb{R}$ )

$$p(x) = \frac{1}{\sqrt{2\pi}\sigma} \exp\left[-\frac{(x - \mu)^2}{2\sigma^2}\right]$$

ein Spezialfall davon ist.

*Hinweis:* Zeigen Sie, dass der Ausdruck unter dem Exponent als Skalarprodukt  $\langle \varphi(x), w \rangle$  geschrieben werden kann. Wie ergeben sich daraus die Abbildung  $\varphi$  und der Parametervektor  $w$ ?

**b)** Man betrachte das überwachte Lernen des Parametervektors  $w$  nach dem Maximum-Likelihood Prinzip. Gegeben sei eine Lernstichprobe  $L = ((x^1, y^1), (x^2, y^2) \dots (x^l, y^l))$ . Leiten Sie den Gradient des log-Likelihoods  $\partial \ln p(L) / \partial w$  ab. Wie ergeben sich daraus die Bedingungen für ein lokales Optimum des log-Likelihoods?

**c)** Wir modifizieren das Modell, indem wir die ursprüngliche Formel als bedingte Wahrscheinlichkeitsverteilung verstehen, d.h. das Modell ist jetzt  $p(x, y) = p(x) \cdot p(y|x)$  mit

$$p(y|x) = \frac{1}{Z(x)} \exp(\langle \varphi(x, y), w \rangle)$$

und einer beliebigen Wahrscheinlichkeitsverteilung  $p(x)$ . Die Normierungskonstante ist jetzt  $x$ -spezifisch, d.h.

$$Z(x) = \sum_y \exp(\langle \varphi(x, y), w \rangle)$$

und sorgt dafür, dass die bedingten Wahrscheinlichkeitsverteilungen für alle  $x$  auf 1 normiert sind. Leiten Sie für diesen Fall den Gradient des log-Conditional Likelihoods ab und vergleichen Sie ihn mit **b**).