

Blatt 9: Schranken für große Abweichungen und Klassifikationsfehler bei linearer Klassifikation

Abgabe Montag, 29. Januar 2001, in der Vorlesung

11. *Schranken für große Abweichungen:* In der Vorlesung wurden einige Abschätzungen für die Wahrscheinlichkeit einer großen Abweichung  $P\{X - EX \geq \varepsilon\}$  einer Zufallsvariable  $X$  vorgestellt.

In dieser Übung sollen die Abschätzungen qualitativ verglichen werden. Im einzelnen betrachtet werden:

(1) Bernoulliverteilung  $B(p)$  zu  $0 \leq p \leq 1$ .  $X$  ist  $B(p)$  verteilt, wenn  $X \in \{0, 1\}$  und  $P\{X = 1\} = p$ ,  $P\{X = 0\} = 1 - p$ .

(2) Normalverteilt  $N(\mu, \sigma)$ , mit Parametern  $(\mu, \sigma^2) \in \mathbb{R} \times \mathbb{R}_+$ , Dichte

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

Bearbeiten Sie nun folgende Aufgaben.

- (a) Bestimmen Sie  $P\{X - EX \geq \varepsilon\}$  für  $B(p)$  verteiltes  $X$ . Die entsprechende Formel für die Normalverteilung läßt sich nicht geschlossen darstellen. Sie können jedoch Näherungen durch die Matlab Funktion `erf` berechnen.

Plotten Sie die tatsächlichen Wahrscheinlichkeiten von  $B(p)$  und  $N(0, \sigma^2)$  gegen Abschätzungen der Markov- und Chebyshev-Ungleichung. Variieren Sie die Parameter. **(3P)**

- (b) Wir gehen nun zu Summen von unabhängig, identisch verteilten Zufallsvariablen über. Sei  $X_i \sim B(p)$  ( $i \in \mathbb{N}$ ).

Die Verteilung von  $S_n := \sum_{i=1}^n X_i$  ist gegeben durch die Binomialverteilung:  $P\{S_n = k\} = \binom{n}{k} p^k (1-p)^{n-k}$ . Bestimmen Sie  $E(S_n)$ .

Plotten Sie die tatsächlichen Wahrscheinlichkeiten  $P\{S_n - ES_n \geq \varepsilon\}$ , sowie die Abschätzungen durch die Hoeffdings- und die Bernstein-Ungleichung. **(3P)**

12. *Klassifikationsfehler von linearer Klassifikation:* In der Vorlesung wurde folgendes Resultat zitiert: Sei  $\mathcal{H}$  die Menge aller Hyperebenen. Falls  $n \geq d$  und  $2d/n \leq \varepsilon \leq 1$ , gilt für die Hyperebene  $\hat{\phi}$ , welche den empirischen Fehler  $R_{\text{emp}}$  minimiert,

$$P\{R(\hat{\phi}) > \inf_{\phi \in \mathcal{H}} R(\phi) + \varepsilon\} \leq e^{2d\varepsilon} \left(2 \binom{n}{d} + 1\right) e^{-n\varepsilon^2/2}, \quad (1)$$

Außerdem gilt, falls  $n \geq d$ ,

$$E\{R(\hat{\phi}) - \inf_{\phi \in \mathcal{H}} R(\phi)\} \leq \sqrt{\frac{2}{n}((d+1) \log n + (2d+2))}. \quad (2)$$

Diese Abschätzungen gelten nicht für die Hyperebene, welche den mittleren quadratischen Fehler minimiert (siehe Aufgabe 10). Das Verhalten dieser Hyperebene soll jetzt mit obigen Gleichungen verglichen werden.

- (a) Generieren Sie einen Datensatz wie in Aufgabe 3 (a) mit  $P(\omega) = \frac{1}{2}$ ,  $\omega \in \{1, 2\}$ ,  $\mu_1 = (-5, 0)^t$ ,  $\mu_2 = (3, 3)$ ,  $\Sigma_1 = \Sigma_2 = \begin{pmatrix} 5 & 0 \\ 0 & 5 \end{pmatrix}$ . Die optimale Diskriminanzfläche  $\phi^*$  ist dann eine Linie (wieso?). Bestimmen Sie  $\phi^*$ . Bestimmen Sie durch Sampling den erwarteten Klassifikationsfehler  $\inf_{\phi \in \mathcal{H}} R(\phi) =: R^*$ . **(3P)**
- (b) Nun soll das Verhalten der Widrow-Hoff-Lernregel (siehe Aufgabe 10) mit den Gleichungen (1) und (2) verglichen werden. Ziehen Sie hierzu einen Datensatz, lernen Sie mittels Widrow-Hoff auf einem Teil der Daten und schätzen Sie den Klassifikationsfehler  $R(\hat{\phi})$  auf den restlichen Daten ab. Tragen Sie die  $R(\hat{\phi}) - R^*$  in ein Histogramm ein. Wiederholen Sie den Vorgang für  $k = 100$  Durchläufe. Bestimmen Sie nun angenäherte Werte  $\tilde{P}\{R(\hat{\phi}) - R^* \geq \varepsilon\}$  und  $\tilde{E}\{R(\hat{\phi}) - R^*\}$  aus dem Histogramm und vergleichen Sie diese mit Gleichungen (1) und (2). **(5P)**