



1. und 2. Übungsblatt

- Wir betrachten eine gleichmäßig auf dem Intervall $[a, b]$ verteilte mathematische Stichprobe X_1, \dots, X_n (d.h. $X_1, \dots, X_n \sim U([a, b])$ i.i.d.) mit unbekanntem Parametern $-\infty < a < b < \infty$.
 - Formalisieren Sie das statistische Modell.
 - Bestimmen Sie Maximum-Likelihood-Schätzer für a und b .
 - Welchen MSE haben die Maximum-Likelihood-Schätzer?
- In einem Krankenhaus soll zur Hebammenplanung mit 95% Sicherheit eine Obergrenze für die Verteilung der Geburtenzahl pro Tag angegeben werden. Bekannt sind die Geburtenzahlen N_1, \dots, N_n der vergangenen n Tage.
 - Begründen Sie, weshalb N_1, \dots, N_n näherungsweise als unabhängig und Poiss(λ)-verteilt mit unbekanntem Parameter $\lambda > 0$ angesehen werden können. Geben Sie das entsprechende statistische Modell an.
 - Untersuchen Sie in dem Modell den Schätzer $\hat{\lambda} = (N_1 + \dots + N_n)/n$ auf Erwartungstreue, Konsistenz und MSE. Weisen Sie nach, dass $\hat{\lambda}$ ML-Schätzer von λ ist.
 - Zeigen Sie für große n unter Verwendung der Normalapproximation und des $N(0, 1)$ -Quantils q_α , dass

$$I = \left[0, \hat{\lambda} + \frac{q_{0,95}}{\sqrt{n}} \sqrt{\hat{\lambda} + \frac{q_{0,95}^2}{4n} + \frac{q_{0,95}^2}{2n}} \right]$$

approximativ ein einseitiges 95%-Konfidenzintervall für λ ist. Für $n \rightarrow \infty$ und

$$\tilde{I}_n = \left[0, \hat{\lambda} + \frac{\sqrt{\hat{\lambda}} q_{0,95}}{\sqrt{n}} \right]$$

gilt $\lim_{n \rightarrow \infty} \mathbb{P}_\lambda(\lambda \in \tilde{I}_n) = 0,95$, $\lambda > 0$ beliebig (\tilde{I}_n ist asymptotisches 95%-Konfidenzintervall).

Hinweis: Sie dürfen das Lemma von Slutsky aus Stochastik II bzw. der Vorlesung verwenden.

3. Die Beta-Verteilung $B(a, b)$ auf $[0, 1]$ ist gegeben durch die Dichte

$$f_{a,b}(x) = \frac{\Gamma(a+b)}{\Gamma(a)\Gamma(b)} x^{a-1}(1-x)^{b-1}, \quad x \in (0, 1),$$

wobei $a, b > 0$ und Γ die Gamma-Funktion bezeichnet. $B(a, b)$ hat Erwartungswert $\mu_{a,b} = \frac{a}{a+b}$ und Varianz $\sigma_{a,b}^2 = \frac{ab}{(a+b)^2(a+b+1)}$.

- (a) Skizzieren Sie $f_{a,b}$ für $(a, b) \in \{0.5; 1; 10\}^2$ (Computereinsatz gestattet).
- (b) Die Beobachtung X sei $\text{Bin}(n, p)$ -verteilt, wobei $n \geq 1$ bekannt ist sowie der unbekannte Parameter p gemäß $B(a, b)$ a priori verteilt ist. Zeigen Sie, dass der Bayes-optimale Schätzer (bzgl. MSE und $B(a, b)$) gegeben ist durch

$$\hat{p}_{a,b} = \frac{a + X}{a + b + n}.$$

- (c) Bestimmen Sie den MSE $R(p, \hat{p}_{a,b})$ als Funktion von p . Bestimmen Sie $a^*, b^* > 0$ so, dass $\max_{p \in [0,1]} R(p, \hat{p}_{a^*, b^*})$ minimal ist.
 - (d) Zeigen Sie, dass $R(p, \hat{p}_{a^*, b^*})$ konstant in p ist. Schließen Sie, dass \hat{p}_{a^*, b^*} minimax-Schätzer ist und der ML-Schätzer $\hat{p} = \frac{X}{n}$ nicht minimax ist.
4. Unter N Wahlberechtigten gibt es N_{AfD} AfD-Wähler sowie jeweils $N/2$ Männer bzw. Frauen.
- (a) Für gerades $n \in \mathbb{N}$ ziehe jeweils zufällig (mit Zurücklegen) $n/2$ Männer und $n/2$ Frauen und bestimme jeweils die Anzahl X_m bzw. X_w von AfD-Wählern/innen in den Stichproben. Formalisieren Sie das statistische Modell und zeigen Sie, dass $\hat{p}_{m/w} := \frac{X_m + X_w}{n}$ ein erwartungstreuer Schätzer von $p = N_{AfD}/N$ ist, dessen MSE nicht größer ist als der von $\hat{p} = \frac{X}{n}$ aus der Vorlesung.
 - (b) Angenommen die Anzahl der AfD-Wähler unter den Männern ist etwa dreimal so groß wie der unter den Frauen. Wie können Sie durch geeignete Stichprobenzahlen einen erwartungstreuen Schätzer von p konstruieren, der noch kleineren MSE als $\hat{p}_{m/w}$ besitzt? (Stichwort: *stratified sampling*).

5. Jede Woche werden n Wahlberechtigte gefragt, ob Sie momentan CDU/CSU wählen würden. Die Anzahl der CDU/CSU-Wähler in Woche $i = 1, \dots, I$ sei als X_i notiert.
- Unter welchen Modell-Voraussetzungen kann man $X_i \sim \text{Bin}(n, p_i)$ mit $p_i \in [0, 1]$ unbekannt sowie $(X_i)_{1 \leq i \leq I}$ unabhängig annehmen?
 - Es gelte das Modell in (a). Zeigen Sie, dass $\hat{p} = \frac{1}{I} \sum_{i=1}^I \frac{X_i}{n}$ erfüllt: $\mathbb{E}_{p_1, \dots, p_I}[\hat{p}] = p := \frac{1}{I} \sum_{i=1}^I p_i$, $\text{Var}_{p_1, \dots, p_I}(\hat{p}) \leq \frac{p(1-p)}{nI}$.
 - Nun sei $I \in \mathbb{N}$ eine gerade Zahl sowie $\hat{v} = \frac{2}{I} \sum_{i=1}^{I/2} \frac{(X_{2i} - X_{2i-1})^2}{n^2}$ ein Schätzer der Fluktuationen von X_i/n . Weisen Sie nach, dass $\mathbb{E}_{p_1, \dots, p_I}[\hat{v}] \geq 2 \frac{p(1-p)}{n}$ gilt. Erklären Sie damit in eigenen Worten die Umfragedifferenzwertanalyse unter www.wahlrecht.de/lexikon/studie.html.
6. Praktische Aufgabe.
- Lesen Sie Kapitel 2.3 “Introduction to R” im Buch “Introduction to Statistical Learning” aus der Literaturliste, um sich mit den grundlegenden Funktionen von R vertraut zu machen. Die dort verwendete Datei “Auto.data” finden Sie unter www-bcf.usc.edu/~gareth/ISL/Auto.data.
 - Bearbeiten Sie Aufgabe 2.4.10 aus demselben Buch.

Aufgaben 1-3 werden korrigiert. Die Abgabe (in Zweier-Gruppen) erfolgt **vor** der Vorlesung am Freitag, 3.11.17.

Die Aufgaben 4-6 sind für die Übung am Dienstag, 7.11.17, schriftlich auszuarbeiten.



3. Übungsblatt

1. Beweisen Sie den *Korrespondenzsatz* für Tests und Konfidenzbereiche:

(a) Ist $C_{1-\alpha}$ eine $(1 - \alpha)$ -Konfidenzmenge für $\vartheta \in \Theta$, so ist für jedes $\vartheta_0 \in \Theta$

$$\varphi^{(\vartheta_0)}(x) = \mathbf{1}(\vartheta_0 \notin C_{1-\alpha}(x))$$

ein Test vom Niveau α für $H_0 : \vartheta = \vartheta_0$ gegen $H_1 : \vartheta \neq \vartheta_0$.

(b) Ist andererseits $(\varphi^{(\vartheta_0)})_{\vartheta_0 \in \Theta}$ eine Familie von nicht-randomisierten Tests für $H_0 : \vartheta = \vartheta_0$ gegen $H_1 : \vartheta \neq \vartheta_0$ zum Niveau α , so ist

$$C_{1-\alpha}(x) = \{\vartheta_0 \in \Theta \mid \varphi^{(\vartheta_0)}(x) = 0\}$$

eine $(1 - \alpha)$ -Konfidenzmenge.

(c) Welche Form hat die Konfidenzmenge in (b), wenn die $\varphi^{(\vartheta_0)}$ jeweils Likelihood-Quotienten-Tests sind? Nehmen Sie der Einfachheit halber an, dass Θ ein metrischer Raum ohne isolierte Punkte und die Likelihood-funktion L in ϑ stetig ist.

2. Es sei X $\text{Bin}(n, p)$ -verteilt mit $p \in [0, 1]$ unbekannt. Zeigen Sie:

(a) Für $p_0 \in (0, 1)$ und das Testproblem $H_0 : p = p_0$ gegen $H_1 : p \neq p_0$ hat der Likelihood-Quotienten-Test die Form

$$\varphi_\alpha = \mathbf{1}\left(\frac{\hat{p}^X(1 - \hat{p})^{n-X}}{p_0^X(1 - p_0)^{n-X}} > c_\alpha\right) + \gamma_\alpha \mathbf{1}\left(\frac{\hat{p}^X(1 - \hat{p})^{n-X}}{p_0^X(1 - p_0)^{n-X}} = c_\alpha\right)$$

mit $\hat{p} = X/n$ und $c_\alpha \geq 0$, $\gamma_\alpha \in [0, 1]$ geeignet.

(b) Eine Münze wird zehnmal unabhängig geworfen und die Anzahl von 'Kopf' notiert. Bestimmen Sie einen Likelihood-Quotienten-Test für die Hypothese einer fairen Münze ($p_0 = 0,5$), der das Niveau $\alpha = 0,05$ exakt ausschöpft.

(c) 2015 wurden in Berlin 38 030 Kinder geboren, darunter 19 614 Jungen. Die Wahrscheinlichkeit einer Jungengeburt sei p . Bestimmen Sie für den Test auf $H_0 : p = 0,5$ die kritischen Werte mittels Normalapproximation und geben Sie für die Daten von 2015 den p-Wert an.

- (d) Bei einer Wahlbefragung unter 1000 Wahlberechtigten erhalten die Grünen 6,4% der Stimmen. Welchen p -Wert ergibt ein Test auf die Null-Hypothese, dass die Grünen an der 5%-Hürde scheitern (mit Normalapproximation)?
3. Betrachten Sie das lineare Modell $Y = X\beta + \varepsilon$, wobei die Fehler ε $N(0, \Sigma)$ -verteilt seien. Weisen Sie nach, dass der Kleinste-Quadrate-Schätzer $\hat{\beta}$ Maximum-Likelihood-Schätzer ist. Bestimmen Sie im Fall $\Sigma = \sigma^2 E_n$ mit $\sigma > 0$ unbekannt einen Maximum-Likelihood-Schätzer für (β, σ) . Auf welche Schätzmethode führt der ML-Ansatz im Fall $\varepsilon_i \sim f_\varepsilon$ i.i.d. mit der Laplace-Dichte $f_\varepsilon(x) = \frac{1}{2\sigma} e^{-|x|/\sigma}$, $x \in \mathbb{R}$?
4. Praktische Aufgabe.
- (a) Lesen Sie Kapitel 3.6 “Lab: Linear Regression” im Buch “Introduction to Statistical Learning”.
- (b) Bearbeiten Sie Aufgabe 3.7.15 aus demselben Buch.

Die Abgabe von Aufgaben 1-2 erfolgt **vor** der Vorlesung am Dienstag, 14.11.17.
Die Aufgaben 3-4 sind für die Übung schriftlich auszuarbeiten.



4. Übungsblatt

1. Es sei $Y = X\beta + \varepsilon$ ein gewöhnliches lineares Modell mit $\varepsilon \sim N(0, \sigma^2 E_n)$. Wir untersuchen den Bayesansatz unter der a-priori-Verteilung $\beta \sim N(0, \tau^2 E_p)$, wobei $\sigma, \tau > 0$. Zeigen Sie:

- (a) Die a-posteriori-Verteilung des Parameters β ist $\beta \sim N(\mu_\beta, \Sigma_\beta)$ mit $\Sigma_\beta = (\sigma^{-2} X^\top X + \tau^{-2} E_p)^{-1}$, $\mu_\beta = \sigma^{-2} \Sigma_\beta X^\top Y$. Inwiefern ist das Verhalten für $\tau \rightarrow 0$ bzw. $\sigma \rightarrow 0$ jeweils plausibel?
- (b) Der Bayesschätzer ist ein *penalisierter* Kleinste-Quadrate-Schätzer (auch *ridge regression estimator* genannt)

$$\hat{\beta}_{\text{Bayes}} = \operatorname{argmin}_{\beta \in \mathbb{R}^p} \left(|Y - X\beta|^2 + \frac{\sigma^2}{\tau^2} |\beta|^2 \right).$$

- (c) Ist λ_p der kleinste Eigenwert von $X^\top X$, so ist λ_p^{-1} der größte Eigenwert von der Kovarianzmatrix $\operatorname{Cov}(\hat{\beta})$ des Kleinste-Quadrate-Schätzers sowie $\lambda_p(\lambda_p + \sigma^2/\tau^2)^{-2}$ von $\operatorname{Cov}(\hat{\beta}_{\text{Bayes}})$. Was bedeutet das statistisch?

2. Betrachten Sie das statistische Modell

$$Y_i = f(x_i) + \varepsilon_i, \quad i = 1, \dots, n,$$

mit n verschiedenen Punkten $x_i \in \mathbb{R}$, $f : \mathbb{R} \rightarrow \mathbb{R}$ beliebig und unbekannt sowie $\mathbb{E}[\varepsilon] = 0$, $\operatorname{Cov}(\varepsilon) = \sigma^2 E_n$. Unter der polynomiellen Regressionsannahme $f = q_a^d$ mit

$$q_a^d(x) = a_0 + a_1 x + \dots + a_d x^d$$

sei $\hat{a} = (\hat{a}_0, \dots, \hat{a}_d)$ der Kleinste-Quadrate-Schätzer sowie $q_{\hat{a}}^d(x)$ die Vorhersage des Funktionswerts an der Stelle $x \in \mathbb{R}$. Zeigen Sie unter der Verwendung der *empirischen Norm* $\|g\|_n^2 = \frac{1}{n} \sum_{i=1}^n g(x_i)^2$ einer Funktion $g : \mathbb{R} \rightarrow \mathbb{R}$:

- (a) Unter der Annahme $f = q_a^d$ gilt $\mathbb{E}_{q_a^d}[\|q_{\hat{a}}^d - q_a^d\|_n^2] = \frac{\sigma^2}{n}(d+1)$.
Tipp: Betrachten Sie $|X\hat{\beta} - X\beta|^2$ im allgemeinen linearen Modell.
- (b) Für f beliebig im Modell ergibt sich die Bias-Varianz-Zerlegung

$$\mathbb{E}_f[\|q_{\hat{a}}^d - f\|_n^2] = \min_{q_a^d} \|f - q_a^d\|_n^2 + \frac{\sigma^2}{n}(d+1),$$

wobei sich der Bias durch den kleinsten Abstand von f zum Raum der Polynome vom maximalen Grad d in empirischer Norm ergibt.

- (c) Geben Sie ein konkretes Beispiel an, wo f ein quadratisches Polynom ist, aber q_a^d für $d = 1$ kleineren Fehler im obigen Sinn besitzt als für $d = 2$.
3. Eine physikalische Größe $\mu \in \mathbb{R}$ wird in n verschiedenen Apparaturen gemessen. Für die Messwerte Y_1, \dots, Y_n nehmen wir $\mathbb{E}[Y_i] = \mu$, $\text{Var}(Y_i) = \sigma_i^2$ mit $\sigma_i > 0$ bekannt und $\text{Cov}(Y_i, Y_j) = 0$ für $i \neq j$ an. Schreiben Sie dies als lineares Modell und weisen Sie nach, dass das gewichtete Mittel

$$\hat{\mu} = \frac{\sum_{i=1}^n \sigma_i^{-2} Y_i}{\sum_{i=1}^n \sigma_i^{-2}}$$

Kleinste-Quadrate-Schätzer ist. Vergleichen Sie die Varianz von $\hat{\mu}$ mit der des Stichprobenmittels \bar{Y} und beweisen Sie dann formal, dass $\hat{\mu}$ kleinste Varianz unter allen linearen erwartungstreuen Schätzern besitzt.

4. Melanom-Prognose: Lösen Sie Aufgabe 2.1.10.1 auf Seite 66 und Aufgabe 2.2.10.2 auf Seite 83 des Buchprojekts. Erklären Sie zuvor den Begriff des Prognoseintervalls.

Zusatzaufgabe: Lesen Sie Kapitel 2 bis einschließlich Abschnitt 2.2.2 und machen Sie Verbesserungsvorschläge.

Die Abgabe von Aufgaben 1-2 erfolgt **vor** der Vorlesung am Dienstag, 21.11.17.
Die Aufgaben 3-4 sind für die Übung schriftlich auszuarbeiten.



5. Übungsblatt

1. Das Modell der einfaktoriellen Kovarianzanalyse (ANCOVA: analysis of covariance) mit $p \in \mathbb{N}$ Beobachtungsgruppen vom Umfang n_1, \dots, n_p lautet

$$Y_{ij} = \mu_i + \kappa x_{ij} + \varepsilon_{ij}, \quad j = 1, \dots, n_i, i = 1, \dots, p,$$

mit unbekanntem Gruppenmittelwerten $\mu_1, \dots, \mu_p \in \mathbb{R}$, unbekanntem Regressionskoeffizienten $\kappa \in \mathbb{R}$, welcher die Abhängigkeit von einem Regressorvektor $x = (x_{ij}) \in \mathbb{R}^{\sum_{i=1}^p n_i}$ angibt und voneinander unabhängigen Störgrößen $\varepsilon_{ij} \sim \mathcal{N}(0, \sigma^2)$ mit (unbekannter) Varianz $\sigma^2 > 0$.

- (a) Bestimmen Sie die Designmatrix und den Parametervektor des zugehörigen linearen Modells und stellen Sie durch eine (notwendige und hinreichende) Bedingung an x sicher, dass die Designmatrix vollen Rang hat.
(b) Bestimmen Sie den Kleinste-Quadrate-Schätzer $\hat{\beta} = (\hat{\mu}_1, \dots, \hat{\mu}_p, \hat{\kappa})^\top$.
(c) Verifizieren Sie die Streuungszerlegung

$$\begin{aligned} \sum_{i=1}^p \sum_{j=1}^{n_i} (Y_{ij} - \bar{Y}_{\bullet\bullet})^2 &= \sum_{i=1}^p \sum_{j=1}^{n_i} (Y_{ij} - \hat{\kappa} x_{ij} - (Y_{i\bullet} - \hat{\kappa} x_{i\bullet}))^2 \\ &\quad + \sum_{i=1}^p n_i (\bar{Y}_{i\bullet} - \bar{Y}_{\bullet\bullet})^2 + \hat{\kappa}^2 \sum_{i=1}^p \sum_{j=1}^{n_i} (x_{ij} - \bar{x}_{i\bullet})^2 \end{aligned}$$

in eine Residuenvarianz innerhalb der Gruppen, eine Stichprobenvarianz zwischen den Gruppen, und eine Regressionsvarianz. Bestimmen Sie die Fisher-Statistik für einen Test der Hypothese $H_0 : \mu_1 = \dots = \mu_p$.

2. Es seien Y_i , $i = 1, \dots, k$, unabhängige $\text{Bin}(n_i, p_i)$ -verteilte Beobachtungen mit $p_1, \dots, p_k \in (0, 1)$ unbekannt, $k \geq 2$. Betrachten Sie das Testproblem $H_0 : p_1 = \dots = p_k$ gegen $H_1 : \exists j, l : p_j \neq p_l$. Beweisen Sie, dass für die Teststatistik $\mathcal{X}_n := \frac{4}{n} \sum_{i=1}^k (Y_i - \bar{Y})^2$ mit $n = \max(n_1, \dots, n_k)$, $n_1(n), \dots, n_k(n) \rightarrow \infty$ unter H_0 gilt

$$\lim_{n \rightarrow \infty} \mathbb{P}(\mathcal{X}_n > q_{1-\alpha}^{\chi^2(k-1)}) \leq \alpha, \quad \alpha \in (0, 1).$$

Schließen Sie, dass der Test auf Homogenität in der Jungengeburtssrate aus der Vorlesung asymptotisch Niveau α besitzt.

Anleitung: Setzen Sie $Z_{i,n} = (Y_i - n_i(n)p_i) / (\sqrt{n_i(n)p_i(1-p_i)})$ und argumentieren Sie zunächst $\mathbb{P}(\sum_{i=1}^k (Z_{i,n} - \bar{Z}_{\bullet,n})^2 > q_{1-\alpha}^{\chi^2(k-1)}) \rightarrow \alpha$ mittels asymptotischer Normalität und Unabhängigkeit.

Freiwillig: Finden Sie die monatliche Geburtenstatistik für Deutschland (und ggf. weitere Länder) und überprüfen Sie, ob Sie die Annahme homogenen Jungenanteils zum Niveau 10% verwerfen können.

3. Untersuchen Sie im gewöhnlichen linearen Modell $Y = X\beta + \varepsilon$ unter der Normalverteilungsannahme $\varepsilon \sim \mathcal{N}(0, \sigma^2 E_n)$ mit unbekanntem $\beta \in \mathbb{R}^p$ und $\sigma > 0$ folgende lineare Testprobleme:

- (a) Test auf signifikanten Einfluss einer Kovariablen auf die Responsevariable:

$$H_0 : \beta_j = 0 \quad \text{versus} \quad H_1 : \beta_j \neq 0$$

für ein fest vorgegebenes $j \in \{1, \dots, p\}$.

- (b) Test eines Subvektors $\beta^* = (\beta_1^*, \dots, \beta_r^*)^\top \in \mathbb{R}^r$ mit $r \leq p$:

$$H_0 : \beta_j = \beta_j^* \quad \forall j \in \{1, \dots, r\} \quad \text{versus} \quad H_1 : \exists j \in \{1, \dots, r\} : \beta_j \neq \beta_j^*.$$

Stellen Sie diese Hypothesen in der Form $H_0 : K\beta = c$ mit geeigneter Kontrastmatrix K und einem Vektor c dar. Konstruieren Sie die zugehörigen Fisher-Statistiken und bestimmen Sie deren Verteilung.

4. Praktische Aufgabe: Klimaentwicklung.

Arbeiten Sie Beispiel 2.2.34 auf Seite 95 des Buchprojekts zu den jährlichen Temperaturdaten durch. Implementieren Sie die angesprochenen Testprobleme in einer Statistik-Software und bestimmen Sie die p-Werte. Verifizieren Sie die angegebenen Testentscheidungen.

Die Abgabe von Aufgaben 1-2 erfolgt **vor** der Vorlesung am Dienstag, 28.11.17.

Die Aufgaben 3-4 sind für die Übung schriftlich auszuarbeiten.



6. Übungsblatt

1. Beweisen Sie den Satz aus der Vorlesung:
Im verallgemeinerten linearen Modell mit kanonischer Linkfunktion und den Zeilen $x_1, \dots, x_n \in \mathbb{R}^p$ der Designmatrix gilt für die Loglikelihoodfunktion

$$\nabla_{\beta} \ell(\beta, \varphi) = \frac{1}{\varphi} \sum_{i=1}^n (Y_i - \zeta'(\langle x_i, \beta \rangle)) x_i.$$

Ist die Fisher-Informationsmatrix $I(\beta) = \frac{1}{\varphi} \sum_{i=1}^n \zeta''(\langle x_i, \beta \rangle) x_i x_i^{\top}$ positiv-definit für alle β und existiert ein $\hat{\beta}$ mit $\nabla_{\beta} \ell(\hat{\beta}, \varphi) = 0$ (für irgendein $\varphi > 0$), so ist $\hat{\beta}$ eindeutig bestimmter Maximum-Likelihood-Schätzer von β .

2. Weisen Sie nach, dass die Poissonverteilung mit Parameter $\lambda > 0$ eine Exponentialfamilie in $T(k) = k$ bildet mit natürlichem Parameter $\eta = \log \lambda \in \mathbb{R}$. Überprüfen Sie die Identitäten $\mathbb{E}_{\eta}[T] = \zeta'(\eta)$, $\text{Var}_{\eta}(T) = \zeta''(\eta)$.

Betrachten Sie nun das Modell der Poissonregression mit $\log \lambda_i = ax_i + b$ für gegebene Designpunkte $x_1, \dots, x_n \in \mathbb{R}$. Stellen Sie gemäß Aufgabe 1 eine Gleichung für den MLE auf und untersuchen Sie, ob der MLE existiert und eindeutig ist. Wie sieht die Iteration in Fishers Scoring-Methode aus?

3. Geben Sie die Cramér-Rao-Ungleichung samt Voraussetzungen aus der Literatur an. Weisen Sie damit für natürliche Exponentialfamilien nach, dass T erwartungstreuer Schätzer von minimaler Varianz für $\zeta'(\eta) = \mathbb{E}_{\eta}[T]$ für η im Innern des natürlichen Parameterbereichs ist.

4. *IRLS: Iteratively reweighted least squares.*

Beweisen Sie, dass der Iterationsschritt in Fishers Scoring-Methode für logistische Regression mit Designmatrix X gegeben ist durch

$$\hat{\beta}_{m+1} = \operatorname{argmin}_{\beta \in \mathbb{R}^p} |W(\hat{\beta}_m)^{1/2} (Z(\hat{\beta}_m) - X\beta)|^2,$$

wobei $Z(\beta) := X\beta + W(\beta)^{-1}(Y - p(\beta)) \in \mathbb{R}^n$, $p_i(\beta) = \frac{e^{\eta_i}}{1+e^{\eta_i}}$ mit $\eta = X\beta$ und $W(\beta) = \operatorname{diag}(p_i(\beta)(1-p_i(\beta)))_{1 \leq i \leq n}$.

Wie kann man den Iterationsschritt jeweils als gewichtete Kleinste-Quadrate-Methode für ein lineares Modell mit Fehlerkovarianzmatrix Σ deuten?



7. Übungsblatt

1. Betrachten Sie für K Klassen mit Klassenwahrscheinlichkeiten $\pi_k \in [0, 1]$, $\sum_{k=1}^K \pi_k = 1$, Mittelwerten $\mu_k \in \mathbb{R}^d$ und invertierbaren Kovarianzmatrizen $\Sigma_k \in \mathbb{R}^{d \times d}$ die Normalverteilungsmischungsdichte

$$f(x) = \sum_{k=1}^K \pi_k \varphi_{\mu_k, \Sigma_k}(x), \quad x \in \mathbb{R}^d.$$

Weisen Sie nach, dass die *decision boundary* zwischen Klasse k und ℓ (bei Standard-Klassifikationsfehler) gegeben ist durch $\{x \in \mathbb{R}^d \mid \delta_k(x) = \delta_\ell(x)\}$ mit quadratischen Diskriminanten

$$\delta_k(x) = -\frac{1}{2} \log(\det(\Sigma_k)) - \frac{1}{2} \langle \Sigma_k^{-1}(x - \mu_k), x - \mu_k \rangle + \log \pi_k, \quad k = 1, \dots, K.$$

Skizzieren Sie eine typische *decision boundary* im Fall $K = d = 2$.

2. Betrachten Sie das Optimierungsproblem

$$\min_{\beta_0 \in \mathbb{R}, \beta \in \mathbb{R}^d} \left(\frac{1}{2} |\beta|^2 + C \sum_{i=1}^n (1 - y_i(\langle x_i, \beta \rangle + \beta_0))_+ \right)$$

für gegebene $y_i \in \{-1, +1\}$, $x_i \in \mathbb{R}^d$, $C > 0$. Beweisen Sie:
Die Lösung für β (deren Existenz vorausgesetzt sei) besitzt die Form

$$\beta = \sum_{i=1}^n \alpha_i y_i x_i \text{ mit } \alpha_i \in [0, C].$$

Punkte x_i mit $\alpha_i > 0$ heißen *Stützvektoren* (*support vectors*). Punkte x_i mit $y_i(\langle x_i, \beta \rangle + \beta_0) > 1$ sind keine Stützvektoren (sie liegen jenseits des *margin*). Für Punkte x_i mit $y_i(\langle x_i, \beta \rangle + \beta_0) < 1$ gilt $\alpha_i = C$ und diese x_i sind Stützvektoren.

Hinweis: $f(z) := z_+ = \max(z, 0)$ ist nicht differenzierbar bei $z = 0$, aber für den Differenzenquotienten gilt $\frac{f(h) - f(0)}{h} \in [0, 1]$ für alle $h \neq 0$.

3. Lesen Sie Abschnitt 4.4.5 *Logistic Regression or LDA?* im Buch *The Elements of Statistical Learning* (<https://web.stanford.edu/~hastie/Papers/ESLII.pdf>). Konstruieren Sie ein konkretes einfaches Beispiel (z.B. mit $K = 2$, $d = 1$), wo LDA besser klassifiziert als logistische Regression.

4. Praktische Aufgabe.

- (a) Lesen Sie Kapitel 4.6 “Lab: Logistic Regression, LDA, QDA and KNN” im Buch *Introduction to Statistical Learning*.
- (b) Bearbeiten Sie Aufgabe 4.7.10(a,d-h) aus demselben Buch.
- (c*) Probieren Sie, bessere Klassifikationsmethoden gemäß Aufgabe 4.7.10(i) zu finden.

Die Abgabe von Aufgaben 1-2 erfolgt **vor** der Vorlesung am Dienstag, 12.12.17.
Aufgabe 3 ist für die Übung am 12.12., Aufgabe 4 für den 19.12. auszuarbeiten.



8. Übungsblatt

1. Empirische Risikominimierung.

Es seien $R, R_n : \mathcal{H} \rightarrow [0, \infty)$ Funktionen auf einer Menge \mathcal{H} ($R(h)$ ist Risiko des statistischen Verfahrens h , $R_n(h)$ das empirische/geschätzte Risiko). Es gelte $\hat{h}_n \in \operatorname{argmin}_{h \in \mathcal{H}} R_n(h)$. Zeigen Sie für das Risiko des empirischen Risikominimierers \hat{h}_n die Fundamentalungleichung:

$$R(\hat{h}_n) \leq \inf_{h \in \mathcal{H}} R(h) + 2 \sup_{h \in \mathcal{H}} |R_n(h) - R(h)|.$$

2. Zur Beschreibung zeitlicher Entwicklungen mit deterministischer Wachstumstendenz und zufälligen Störungen verwendet man oft das folgende *autoregressive Modell* (der Ordnung 1):

$$X_k = \gamma X_{k-1} + \varepsilon_k, \quad k = 1, \dots, n.$$

Dabei sind $\gamma \in \mathbb{R}$ unbekannt, X_0, \dots, X_n die Beobachtungen und $\varepsilon_1, \dots, \varepsilon_n$ unabhängige zufällige Störungen mit $\mathbb{E}[\varepsilon_k] = 0$ und $\operatorname{Var}(\varepsilon_k) = \sigma^2 > 0$.

- Auf welchen Schätzer von γ führt ein Kleinste-Quadrate-Ansatz?
- Unter welcher Verteilungsannahme an (ε_k) ist der Kleinste-Quadrate-Schätzer auch Maximum-Likelihood-Schätzer?
- Ist dieser Schätzer erwartungstreu?

3. In einer Umfrage werden $n \in \mathbb{N}$ vierköpfige Familien nach der Anzahl ihrer Fußballfans befragt. Wir nehmen an, dass die Beobachtungen $Y_1, \dots, Y_n \in \{0, \dots, 4\}$ unabhängig voneinander $\operatorname{Bin}(p_i, 4)$ -verteilt sind mit unbekanntem Parametern $p_1, \dots, p_n \in (0, 1)$. Ein Fernsehsender identifiziert $k \in \mathbb{N}$ relevante Kovariablen und modelliert die Wahrscheinlichkeiten p_i über den Vektor $\eta = (\log \frac{p_1}{1-p_1}, \dots, \log \frac{p_n}{1-p_n})^\top \in \mathbb{R}^n$ mit $\eta = X\beta$ für eine Designmatrix $X \in \mathbb{R}^{n \times k}$ und einen unbekanntem Parametervektor $\beta \in \mathbb{R}^k$. Weisen Sie nach, dass ein verallgemeinertes lineares Modell vorliegt. Was ist der natürliche Parameterraum? Wird die kanonische Linkfunktion verwendet?

Die Abgabe von Aufgabe 1 erfolgt **vor** der Vorlesung am Dienstag, 19.12.17.
Aufgaben 2-3 sind für die Übung schriftlich auszuarbeiten.

Wir wünschen Ihnen frohe Weihnachtstage und einen guten Start ins Jahr 2018!



9. Übungsblatt

- Bestimmen Sie die Kullback-Leibler-Divergenz $\text{KL}(N(\mu_1, \Sigma_1) \mid N(\mu_2, \Sigma_2))$ zwischen zwei d -dimensionalen Normalverteilungen mit $\mu_1, \mu_2 \in \mathbb{R}^d$ und symmetrischen, positiv-semidefiniten Matrizen $\Sigma_1, \Sigma_2 \in \mathbb{R}^{d \times d}$.
- Wir betrachten ein Produktmodell $(\mathcal{X}^n, \mathcal{F}^{\otimes n}, (\mathbb{P}_\vartheta^{\otimes n})_{\vartheta \in \Theta})$.

- Zeigen Sie, dass die Kullback-Leibler-Divergenz für Produktmaße additiv ist:

$$\text{KL}(\mathbb{P}_\vartheta^{\otimes n} \mid \mathbb{P}_{\vartheta'}^{\otimes n}) = n \text{KL}(\mathbb{P}_\vartheta \mid \mathbb{P}_{\vartheta'}) \quad \forall \vartheta, \vartheta' \in \Theta.$$

- Es gelte außerdem $\mathbb{P}_\vartheta \ll \mathbb{P}_{\vartheta'}$ für alle $\vartheta, \vartheta' \in \Theta$ und $\ell(\vartheta, x) := \log L(\vartheta, x)$ sei die Loglikelihood-Funktion von \mathbb{P}_ϑ bezüglich einem \mathbb{P}_{ϑ^*} . Weisen Sie für alle $\vartheta_0 \in \Theta$ nach, dass

$$-\frac{1}{n} \sum_{i=1}^n \ell(\vartheta, x_i) \xrightarrow{\mathbb{P}_{\vartheta_0}^{\otimes n}} \text{KL}(\mathbb{P}_{\vartheta_0} \mid \mathbb{P}_\vartheta) - \text{KL}(\mathbb{P}_{\vartheta_0} \mid \mathbb{P}_{\vartheta^*}) \quad \text{für } n \rightarrow \infty$$

gilt, sofern die Kullback-Leibler-Divergenzen endlich sind. Für welches $\vartheta \in \Theta$ ist die rechte Seite minimal?

- Betrachten Sie die Konvergenz in (b) nun unter $\mathbb{P}^{\otimes n}$ für ein beliebiges Wahrscheinlichkeitsmaß \mathbb{P} mit $\text{KL}(\mathbb{P} \mid \mathbb{P}_\vartheta) < \infty$. Welcher Parameter in Θ ist also der natürliche Grenzwert des Maximum-Likelihood-Schätzers in einem *misspezifizierten Modell*, in dem die wahre Verteilung \mathbb{P} nicht in $(\mathbb{P}_\vartheta)_{\vartheta \in \Theta}$ enthalten ist? (Nehmen Sie an, dass alles wohldefiniert ist und entsprechend konvergiert.)

3. Der *Totalvariationsabstand* zweier Wahrscheinlichkeitsmaße \mathbb{P} und \mathbb{Q} auf einem messbaren Raum $(\mathcal{X}, \mathcal{F})$ ist definiert als

$$\text{TV}(\mathbb{P}, \mathbb{Q}) := \sup_{A \in \mathcal{F}} |\mathbb{P}(A) - \mathbb{Q}(A)|.$$

- (a) Weisen Sie $\text{TV}(\mathbb{P}, \mathbb{Q}) = \frac{1}{2} \int |p - q| d\nu$, nach für ein dominierendes Maß ν und ν -Dichten $p = \frac{d\mathbb{P}}{d\nu}$, $q = \frac{d\mathbb{Q}}{d\nu}$.
- (b) Zeigen Sie $\text{TV}(\mathbb{P}, \mathbb{Q}) \leq \sqrt{\text{KL}(\mathbb{P}|\mathbb{Q})/2}$.
Hinweis: Betrachten Sie die Funktion $h(z) := z \log(z) - z + 1$, $z > 0$, mit stetiger Fortsetzung in Null. Zeigen Sie für alle $z \geq 0$:

$$\left(\frac{4}{3} + \frac{2}{3}z\right)h(z) \geq (z - 1)^2.$$

Benutzen Sie anschließend die Cauchy-Schwarz-Ungleichung.

- (c) Prüfen Sie ob die Folgen $(\mathbb{P}_n)_{n \in \mathbb{N}}$ auf $(\mathbb{R}, \mathcal{B}(\mathbb{R}))$ schwach, im Totalvariationsabstand oder in der Kullback-Leibler-Divergenz gegen einen geeigneten Grenzwert \mathbb{P} konvergieren (betrachten Sie sowohl $\text{KL}(\mathbb{P}_n | \mathbb{P})$ als auch $\text{KL}(\mathbb{P} | \mathbb{P}_n)$):
- (i) $\mathbb{P}_n = \delta_{1/n}$, Dirac-Maß in $1/n$;
- (ii) $\mathbb{P}_n = (1 - \frac{1}{n})\nu + \frac{1}{n}\delta_1$, wobei ν das Maß der $\mathcal{N}(0, 1)$ -Verteilung ist.

4. Praktische Aufgabe: AIC und BIC.

- (a) Vollziehen Sie die Beispiele 5.1.15 und 5.2.4 des Buchprojekts nach, um die Verwendung von AIC und BIC bei der Polynomregression zu verstehen.
- (b) Simulieren Sie ein Polynomregressionsmodell mit $x_i = i/n$, $i = 1, \dots, n$, $\varepsilon_i \sim N(0, 1)$ i.i.d., und Polynomfunktion $p(x) = x^3 - 2x^2 + x$. Bestimmen Sie für $n = 10$, $n = 100$ und $n = 1000$ in jeweils 100 Monte-Carlo-Iterationen:
- den *mittleren Vorhersage-Fehler* $E_k := \frac{1}{n} \sum_{i=1}^n (\hat{p}_k(x_i) - p(x_i))^2$ des geschätzten Polynoms $\hat{p}_k(x) = \sum_{j=0}^k \hat{\beta}_j x^j$ vom Grad k für $k = 0, 1, \dots, 5$,
 - den von AIC und BIC gewählten Polynomgrad \hat{k}^{AIC} , \hat{k}^{BIC} und die zugehörigen Fehler $E_{\hat{k}^{AIC}}$, $E_{\hat{k}^{BIC}}$ zusammen mit den Orakelfehlern $\min_k E_k$.

Stellen Sie Ihre Ergebnisse mittels Boxplots über die Monte-Carlo-Iterationen dar. Wieso wird $\min_k E_k$ nicht stets bei $k = 3$ angenommen?

- (c) Freiwillig: Welche Ergebnisse in (b) ergeben sich, wenn die Daten mittels $Y_i = \sin(\pi x_i) + \varepsilon_i$ erzeugt werden?

Die Abgabe von Aufgaben 1 und 2 erfolgt **vor** der Vorlesung am Dienstag, 16.1.18. Aufgaben 3 und 4 sind für die Übung schriftlich auszuarbeiten.



10. Übungsblatt

1. Betrachten Sie die Beobachtungen $Y = \mu + \varepsilon$ mit $\mu \in \mathbb{R}^n$ und $\varepsilon \sim N(0, \Sigma)$, wobei $\Sigma \in \mathbb{R}^{n \times n}$ bekannt und strikt positiv-definit sei. Leiten Sie (in Analogie zum Fall $\Sigma = \sigma^2 E_n$) für die Modelle $Y = X^{(k)} \beta^{(k)} + \varepsilon$ mit $\beta^{(k)} \in \mathbb{R}^k$ und $X^{(k)} \in \mathbb{R}^{n \times k}$ von vollem Rang k , $k = 1, \dots, K \leq n$, das Akaike-Informationskriterium $AIC(k)$ her. Weisen Sie $\mathbb{E}[AIC(k)] = \mathbb{E}[d(\hat{\beta}_k)]$ nach.
2. Es X_p eine $\chi^2(p)$ -verteilte Zufallsvariable mit $p \in \mathbb{N}$ Freiheitsgraden. Ziel ist eine Abschätzung von


$$\mathbb{P}\left(X_p - \mathbb{E}[X_p] \geq \kappa \sqrt{\text{Var}(X_p)}\right), \quad \kappa > 0.$$

- (a) Berechnen Sie $\mathbb{E}[X_p]$, $\text{Var}(X_p)$, $\mathbb{E}[e^{\lambda X_p}]$ für $\lambda > 0$.
 - (b) Schätzen Sie die Wahrscheinlichkeit mit der (verallgemeinerten) Markovungleichung von oben ab.
 - (c) Minimieren Sie die Schranke durch eine optimale Wahl von λ .
3. Eine zufällige Designmatrix $X^{(n)} \in \mathbb{R}^{n \times k}$, $k \leq n$, sei gegeben durch i.i.d. Beobachtungspunkte $X_1, \dots, X_n \in D$, Ansatzfunktion $\varphi_1, \dots, \varphi_k : D \rightarrow \mathbb{R}$ sowie $X_{ij}^{(n)} = \varphi_j(X_i)$. Wir beobachten $Y = X^{(n)} \beta + \varepsilon$ mit $\beta \in \mathbb{R}^k$, $\varepsilon \sim N(0, \sigma^2 E_n)$ (unabhängig vom Design). Zeigen Sie:
 - (a) Gilt $\varphi_1(X_1), \dots, \varphi_k(X_1) \in L^2$, so konvergiert $\hat{\Sigma}_n := \frac{1}{n} (X^{(n)})^\top X^{(n)}$ für $n \rightarrow \infty$ fast sicher gegen $\Sigma := (\mathbb{E}[\varphi_i(X_1) \varphi_j(X_1)])_{1 \leq i, j \leq k}$. Im Fall $\Sigma > 0$ folgt insbesondere $\mathbb{P}(\text{rank}(X^{(n)}) = k) \rightarrow 1$.
 - (b) Mit der empirischen Norm $\|v\|_n^2 := \frac{1}{n} \sum_{i=1}^n v_i^2$, $v \in \mathbb{R}^n$, gilt $\mathbb{E}[\|X^{(n)} \beta\|_n^2] = \mathbb{E}[\sum_{j=1}^k \beta_j^2 \varphi_j(X_1)^2]$, $\beta \in \mathbb{R}^k$, unabhängig von n .
 - (c) Für den KQ-Schätzer $\hat{\beta}_n$, so er existiert, gilt $\mathbb{E}[\|X^{(n)}(\hat{\beta}_n - \beta)\|_n^2] = \frac{\sigma^2 k}{n}$.
 - (d) Es gilt $\mathbb{E}^\varepsilon[|\hat{\beta}_n - \beta|^2] = \frac{\sigma^2}{n} \text{trace}(\hat{\Sigma}_n^{-1})$ (Erwartungswert nur bzgl. (ε_i)). Schließen Sie $\lim_{n \rightarrow \infty} n \mathbb{E}^\varepsilon[|\hat{\beta}_n - \beta|^2] = \sigma^2 \text{trace}(\Sigma^{-1})$ f.s. für $\Sigma > 0$.
 - (e*) (freiwillig) Gilt auch $\lim_{n \rightarrow \infty} n \mathbb{E}^\varepsilon[|\hat{\beta}_n - \beta|^2] = \sigma^2 \text{trace}(\Sigma^{-1})$ für $\Sigma > 0$?

4. Praktische Aufgabe: Random design regression.

- (a) Im Rahmen von Aufgabe 3 betrachten Sie $X_1, \dots, X_n \sim N(0, 1)$ sowie $\varphi_j(x) = x^j$, $j = 0, 1, \dots, k$. Im wahren Modell gelte $Y_i = X_i^4 + \varepsilon_i$, $i = 1, \dots, n$. Bestimmen Sie für $n \in \{10, 100, 1000\}$, $k = 6$ in jeweils 100 Monte-Carlo-Iterationen den Vorhersagefehler $\|X^{(n)}(\hat{\beta}_n - \beta)\|_n^2$ und den Schätzfehler $|\hat{\beta}_n - \beta|^2$. Stellen Sie die Ergebnisse im Boxplot dar und vergleichen Sie mit den theoretischen Ergebnissen aus Aufgabe 3.
- (b) Führen Sie dieselben Rechnungen durch bei deterministischem Design $x_i = \Phi^{-1}(i/n)$, $i = 1, \dots, n$, wobei Φ^{-1} die Inverse der Verteilungsfunktion (d.h. die Quantilsfunktion) von $N(0, 1)$ bezeichnet.

Die Abgabe von Aufgaben 1 und 2 erfolgt **vor** der Vorlesung am Dienstag, 23.1.18. Aufgaben 3 und 4 sind für die Übung schriftlich auszuarbeiten.



11. Übungsblatt

- (a) Beweisen Sie $\mathbb{E}[X] = \int_0^\infty \mathbb{P}(X > \tau) d\tau$ für eine beliebige Zufallsvariable X mit Werten in $[0, \infty)$.
- (b) Folgern Sie aus dem Hauptsatz zur Modellwahl und unter dessen Voraussetzungen die Orakelungleichung

$$\mathbb{E}[\|\hat{\mu}_m - \mu\|^2] \leq C(K, \kappa) \left(\inf_m \{\|\mu_m - \mu\|^2 + \text{pen}(d_m)\} + \sigma^2 \sum_{m=1}^M e^{-d_m \kappa^2 / 2} \right),$$

für eine Konstante $C(K, \kappa) > 0$.

- In der multiplen linearen Regression

$$Y_i = \beta_0 + \beta_1 x_{i,1} + \dots + \beta_k x_{i,k} + \varepsilon_i \quad \text{für } i = 1, \dots, n$$

mit Kovariablen $(x_{1,\ell}, \dots, x_{n,\ell}), 1 \leq \ell \leq k$, unbekanntem Parametervektor $\beta \in \mathbb{R}^{k+1}$ und Fehlern $\varepsilon_1, \dots, \varepsilon_n \stackrel{iid.}{\sim} \mathcal{N}(0, \sigma^2), \sigma^2 > 0$, soll eine Variablen-selektion durchgeführt werden, um das Modell auf die aktiven Kovariablen zu reduzieren. Welches $\kappa > 0$ muss gewählt werden, um den Term

$$T := \sum_{m=1}^M e^{-d_m \kappa^2 / 2}$$

aus Aufgabe 1 gleichmäßig zu beschränken? Gehen Sie wie folgt vor:

- Zeigen Sie $M = 2^{k+1}$ und $T = \sum_{\ell=1}^{k+1} \binom{k+1}{\ell} e^{-\ell \kappa^2 / 2}$.
- Schätzen Sie $\log \binom{k+1}{\ell}$ linear in ℓ ab und bestimmen Sie κ in Abhängigkeit von k .

3. Das *empirische Skalarprodukt* sei definiert als $\langle f, g \rangle_n := \frac{1}{n} \sum_{i=1}^n f(\frac{i}{n})g(\frac{i}{n})$ bzw. $\langle x, g \rangle_n := \frac{1}{n} \sum_{i=1}^n x_i g(\frac{i}{n})$ für Funktionen f, g auf $[0, 1]$ bzw. $x \in \mathbb{R}^n$. Setze $\|f\|_n^2 := \langle f, f \rangle_n$. Sei $(\varphi_k)_{k=1}^n$ eine Orthonormalbasis bezüglich $\langle \bullet, \bullet \rangle_n$. Für $f(x) = \sum_{k=1}^n \beta_k \varphi_k(x)$, $x \in [0, 1]$, mit Koeffizienten $\beta_1, \dots, \beta_n \in \mathbb{R}$ betrachten wir das Regressionsmodell

$$Y_i = f(\frac{i}{n}) + \varepsilon_i, \quad i = 1, \dots, n,$$

mit unabhängig und identisch $\mathcal{N}(0, \sigma^2)$ -verteilten Fehlern $\varepsilon_i, i = 1, \dots, n$.

- (a) Weisen Sie nach, dass $\hat{\beta}_k := \langle Y, \varphi_k \rangle_n$ Maximum-Likelihood-Schätzer von β_k für $k = 1, \dots, n$ ist.
 (b) Bestimmen Sie für $m \in \{1, \dots, n\}$ den Fehler

$$\mathbb{E} [\|f - \hat{f}_m\|_n^2] \quad \text{für} \quad \hat{f}_m(x) := \sum_{k=1}^m \hat{\beta}_k \varphi_k(x).$$

Auf welches Minimierungsproblem führt eine optimale Wahl von m ?

- (c) Nehmen Sie an, dass es ein $s > 0$ und $0 < c < C$ gibt, so dass $ck^{-s} \leq |\beta_k| \leq Ck^{-s}$ gilt. Wie wächst das optimale m in n ?
4. Es sei ein zweidimensionaler Zufallsvektor (X, Y) mit Lebesgue-dichte $f^{(X,Y)}$ gegeben.

- (a) Bestimmen Sie die bedingte Wahrscheinlichkeit $P(X \leq x | Y \in [y-h, y+h])$ für $x, y \in \mathbb{R}, h > 0$ mit $f^Y(y) > 0$ und f^Y stetig bei y . Zeigen Sie, dass der Grenzwert der bedingten Wahrscheinlichkeit für $h \rightarrow 0$ existiert und gegeben ist durch

$$\frac{\int_{-\infty}^x f^{(X,Y)}(\xi, y) d\xi}{f^Y(y)} =: F^{X|Y=y}(x).$$

- (b) Man definiert daher die *bedingte Dichte* von X gegeben $Y = y$ als

$$f^{X|Y=y}(x) := \frac{\partial}{\partial x} F^{X|Y=y}(x) = \frac{f^{(X,Y)}(x, y)}{f^Y(y)}, \text{ sofern } f^Y(y) > 0.$$

Zeigen Sie, dass $f^{X|Y=y}$ in der Tat eine Dichtefunktion ist für alle y mit $f^Y(y) > 0$ und die Bayesformel für Dichten gilt:

$$f^{X|Y=y}(x) = \frac{f^{(X,Y)}(x, y)}{\int_{\{\xi: f^X(\xi) > 0\}} f^{Y|X=\xi}(y) f^X(\xi) d\xi} \text{ sofern } f^Y(y) > 0.$$

- (c) Verallgemeinern Sie (b) auf Dichten $f^{(X,Y)}$ bezüglich einem allgemeinen Produktmaß $\mu_X \otimes \mu_Y$. Zeigen Sie ferner für $X \in L^1$, dass $\int x f^{X|Y=y}(x) \mu_X(dx)$ die Eigenschaften des bedingten Erwartungswerts $\mathbb{E}[X | Y = y]$ erfüllt.

Die Abgabe von Aufgaben 1 und 2 erfolgt **vor** der Vorlesung am Dienstag, 30.1.18. Aufgaben 3 und 4 sind für die Übung schriftlich auszuarbeiten.



12. Übungsblatt: Probeklausur

1. Entscheiden Sie, ob folgende Aussagen wahr oder falsch sind.
 - (a) Minimax-optimale Schätzer haben für keinen Parameterwert einen größeren Fehler als Bayesschätzer.
 - (b) Die kritischen Werte im Gaußtest leiten sich aus der t -Verteilung her.
 - (c) In der Varianzanalyse wird die Streuung zwischen den Gruppen und die innerhalb der Gruppen mit einem F-Test verglichen.
 - (d) Sind im linearen Modell die Fehler normalverteilt, so ist die Stichprobenvarianz $\hat{\sigma}^2 = |Y - X\hat{\beta}_{\text{KQ}}|^2 / (n - k)$ χ^2 -verteilt.
 - (e) Die Verteilungen $(\text{Bin}(n, p))_{p \in (0,1)}$ bilden eine Exponentialfamilie.
 - (f) Für großen Stichprobenumfang n wählt AIC ein kleineres Modell als BIC.
 - (g) Bei der logistischen Regression modelliert man $Y_i \sim \text{Bin}(1, p_i)$ mit $p_i = \log((X\beta)_i)$, $i = 1, \dots, n$.
 - (h) Der Median von (X_1, \dots, X_n) ist Maximum-Likelihood-Schätzer, wenn die X_i unabhängig sind mit Dichte $f(x) = \frac{\lambda}{2} e^{-\lambda|x|}$, $x \in \mathbb{R}$, wobei $\lambda > 0$ beliebig.
 - (i) Der Unterschied zwischen den Klassifikationen mit *separating hyperplanes* und *support vectors* ist, dass im zweiten Fall falsch klassifizierte Trainingsdaten erlaubt sind, wenn dies einen signifikant größeren *margin* erlaubt.
 - (j) Für Folgen $(P_n)_{n \geq 1}$ und $(Q_n)_{n \geq 1}$ von Maßen auf einem gemeinsamen messbaren Raum gilt: $\text{TV}(P_n, Q_n) \rightarrow 0 \Rightarrow \text{KL}(P_n|Q_n) \rightarrow 0$.
2. Es seien (X, Y) ein Zufallsvektor auf $\mathbb{R}^d \times \{0, 1\}$ sowie $(X_1, Y_1), \dots, (X_n, Y_n)$ unabhängige, wie (X, Y) verteilte Beobachtungen. Für einen Klassifizierer $C : \mathbb{R}^d \rightarrow \{0, 1\}$ betrachte den Klassifizierungsfehler $R(C) := \mathbb{P}(C(X) \neq Y)$.
 - (a) Zeigen Sie, dass der Bayes-Klassifizierer $C_B(x) = \operatorname{argmax}_{k=0,1} \mathbb{P}(Y = k | X = x)$ den Klassifizierungsfehler minimiert. Wieso ist der Bayes-Klassifizierer für den Statistiker unzugänglich?
 - (b) Auf welche Klassifikationsmethode führt der Ansatz, dass X gegeben $\{Y = k\}$ $N(\mu_k, \Sigma)$ -verteilt mit $\mu_0 \neq \mu_1$ und $\Sigma > 0$ ist? Wie sieht die zugehörige Klassifikationsgrenze (*classification boundary*) im \mathbb{R}^d geometrisch aus?

- (c) Setze $d = 1$ und modelliere $\mathbb{P}(X = 0) = 1 - \mathbb{P}(X = 1) = \pi_0 \in (0, 1)$ sowie $f^{Y|X=k}(x) = \lambda_k e^{-\lambda_k x}$, $x \geq 0$, $k = 0, 1$ (exponential-verteilt mit $0 < \lambda_0 < \lambda_1$). Benutzen Sie die Bayesformel, um den Bayesklassifizierer zu bestimmen. Schätzen Sie diesen dann mittels eines Maximum-Likelihood-Schätzers von $(\pi_0, \lambda_0, \lambda_1)$, basierend auf den Daten $(X_1, Y_1), \dots, (X_n, Y_n)$.
3. Betrachten Sie das lineare Modell $Y = X\beta + \varepsilon$ mit $\beta \in \mathbb{R}^k$, $X \in \mathbb{R}^{n \times k}$ mit $\text{rank}(X) = k \leq n$ und $\mathbb{E}[\varepsilon] = 0$, $\text{Cov}(\varepsilon) = \sigma^2 E_n$. Definiere den linearen Schätzer

$$\hat{\beta} = AY \text{ mit } A \in \mathbb{R}^{k \times n} \text{ deterministisch.}$$

- (a) Bestimmen Sie Bias, Varianz und mittleren quadratischen Fehler (MSE) von $\hat{\beta}$ in Abhängigkeit von A .
- (b) Zeigen Sie für Vorhersagefehler und *residual sum of squares* $RSS = |X\hat{\beta} - Y|^2$ den allgemeinen Zusammenhang

$$\mathbb{E}[|X(\hat{\beta} - \beta)|^2] = \mathbb{E}[RSS] + 2\sigma^2 \text{trace}(XA) - \sigma^2 n.$$

- (c) Leiten Sie auf diesem Weg für den Kleinste-Quadrate Schätzer ab, dass das AIC-Kriterium für die Modellwahl die Kullback-Leibler-Devianz erwartungstreu schätzt.
4. Betrachten Sie in Aufgabe 3 nun die *ridge-regression*-Schätzer $\hat{\beta}_\lambda = A_\lambda Y$ mit $A_\lambda = (X^\top X + \lambda E_n)^{-1} X^\top$, $\lambda > 0$.

- (a) Begründen Sie $\hat{\beta}_\lambda = \text{argmin}_{b \in \mathbb{R}^k} |Y - Xb|^2 + \lambda |b|^2$. Ist $\hat{\beta}_\lambda$ auch im Fall $\text{rank}(X) < k$ wohldefiniert?
- (b) Setze $v(\lambda) = \text{Var}(\hat{\beta}_\lambda)$, $\lambda > 0$. Zeigen Sie, dass $v(\lambda)$ monoton fallend in λ ist mit $\lim_{\lambda \downarrow 0} v(\lambda) = \text{Var}(\hat{\beta})$ für den Kleinste-Quadrate-Schätzer $\hat{\beta}$ und $\lim_{\lambda \uparrow \infty} v(\lambda) = 0$. Wieso widerspricht das nicht dem Satz von Gauß-Markov?
- (c) Es seien $s_1 \geq s_2 \geq \dots \geq s_n \geq 0$ die Eigenwerte von $X^\top X$. Weisen Sie mit Aufgabe 3 nach, dass

$$R(\lambda) := |X\hat{\beta}_\lambda - Y|^2 + 2\sigma^2 \sum_{i=1}^n \frac{s_i}{s_i + \lambda} - n$$

ein unverzerrter Schätzer des Vorhersagefehlers $|X(\hat{\beta}_\lambda - \beta)|^2$ ist. Wie könnte man also den *Regularisierungsparameter* λ wählen?