

Seminararbeit: Information einer Stichprobe

Autor: Yingying Zhou

Leitung: PD. Dr. Dr. Christina Schneider

Betreuer: Paul Fink

23.Januar 2015



Inhaltsverzeichnis

1	Einleitung	1
2	Information einer Stichprobe	2
2.1	Regularität der Verteilungsfamilie	2
2.2	Fisher-Information	3
2.2.1	Score-Funktion	3
2.2.2	Fisher-Information einer Stichprobe X	4
2.2.3	Fisher-Information einer Statistik T	5
2.2.4	Hauptsatz der Fisher-Information	6
2.2.5	Fisher-Information mit mehrere Statistiken	8
2.2.6	Fisher-Information mit speziellem Parameter	9
3	Informationsmatrix	10
3.1	Informationsmatrix	10
3.1.1	Fishersche Informationsmatrix einer Stichprobe	10
3.1.2	Fishersche Informationsmatrix einer Statistik	11
	Literaturverzeichnis	13

1 Einleitung

Der folgende Artikel ist eine Zusammenfassung von Dr. B. Rüggers Lehrbuch Test- und Schätztheorie, Band I: Grundlagen (1999): aus Kapitel 1.32-1.33. Mit dem Begriffe der Stichprobe fangen wir mit diesem Artikel an. Der Stichprobe verbindet die folgende Vorstellung: Eine Teilmenge von n Elementen der Grundgesamtheit, wird bezüglich eines interessierenden Merkmals besucht. Das Merkmal wird als Zufallsgröße X definiert, und der spezielle Merkmalswert, den ein Element der Grundgesamtheit aufweist, ist eine Realisierung x von X . Die Zielsetzung der Stichprobe ist die Information über die Wahrscheinlichkeitsverteilung der Zufallsgröße zu gewinnen. Informationen über die unbekannt Verteilung ist eine Zufallsstichprobe. Die Zufallsgröße X der Stichprobe wird n -mal beobachtet. So ergibt eine zufällige Vektor $\{X_1, X_2, \dots, X_n\}$ mit unabhängigen, identisch wie X verteilten Komponenten X_i . Nach i -ten Ablauf der Versuchung entsteht eine Realisierung x_i von X_i : $X_i = x_i$. Die Vektor von der Realisierung ist $\{x_1, x_2, \dots, x_n\}$. Information einer Stichprobe ist nämlich die Information einer Beobachtung einer Zufallsgröße über die unbekannt Verteilung. In die folgende Artikel besteht immer eine Verteilungsannahme $\mathfrak{B} = \{P_\theta : \theta \in \Theta\}$ über die Stichprobe X mit einem unbekannt Parameter θ . [B.Rüger (1999)] (Seite 91) Die Verteilungsannahme $\mathfrak{B} = \{f(x; \theta) : \theta \in \Theta\}$, die voraussetzenden Regularitätseigenschaften besitzt, nennen wir Fisher-reguläre Verteilungsfamilie. Durch der Derivation und Logarithmus der Dichtfunktion von Fisher-reguläre Verteilungsannahme bekommen wir die sogenannte Score-Funktion $K(\theta; X)$ der Stichprobe X als die Grundlage zur Definition der Fisher-Information $I_X(\theta)$. Die Fisher-Information ist Varianz von Score oder Erwartungswert der beobachtete Information $I(\theta; x)$. Sie ist eine Schätzung der Größe von der Beobachtungen der Stichprobe X über den Parameter θ . Eine suffiziente Statistik enthält nur die Informationen der Stichprobe über θ . Die Fisher-Information $I_{T(X)}(\theta)$ von $T = T(X)$ über θ besitzen überstimmende Score-Funktion mit derjenigen von X . Als Folgerung ergibt sich: $I_{T(X)}(\theta) = I_X(\theta)$ für alle θ . Information der Verteilungsannahme mit einem Parametervektor $\theta = (\theta_1, \dots, \theta_r)$ nennen wir Fishersche Informationsmatrix. Das Grundprinzip der Fishersche Informationsmatrix ist analog zu Fisher-Information.

2 Information einer Stichprobe

Information einer Stichprobe enthalten wir die Informationne über eine unbekanntes Parameter θ aus einem zugrundeliegenden Verteilungsfamilie \mathfrak{B} über die Stichprobe X . Das Problem ist, wie viele Informationen kann eine Stichprobe über die unbekanntes Parameter θ abschätzen. In diesem Kapitel betrifft eine Verteilungsannahme $\mathfrak{B} = \{P_\theta : \theta \in \Theta\}$ über die Stichprobe X .

2.1 Regularität der Verteilungsfamilie

Um die Information einer Stichprobe zu erfassen, stets eine Verteilungsannahme $\mathfrak{B} = \{P_\theta : \theta \in \Theta\}$ über die Stichprobe X mit einem unbekanntes Parameter θ . Wir fangen erstens mit der Eigenschaften der Verteilungsannahme \mathfrak{B} einer Stichprobe an.

Eine Verteilungsannahme $\mathfrak{B} = \{P_\theta : \theta \in \Theta\}$ wird mit einem reellem Parameter θ beschränkt, somit $\Theta \subset \mathbb{R}$. Die sogenannte Fisher-reguläre Verteilungsfamilie \mathfrak{B} soll mit den folgenden Regularitätseigenschaften [B.Rüger (1999)](Seite 92) anpassen.

- 1) \mathfrak{B} ist durch ein (σ -finites) Maß ν dominiert, also darstellbar als $\mathfrak{B} = \{f(x; \theta) : \theta \in \Theta\}$.
- 2) Θ ist ein offenes Intervall.
- 3) Die Verteilungen von \mathfrak{B} haben alle denselben Träger, so daß auch $C := \{x : f(x; \theta) > 0\}$ unabhängig von θ ist.
- 4) Die Dichten $f(x; \theta)$ sind für jedes $x \in C$ zweimal nach θ differenzierbar, die betreffenden Ableitungen sind integrierbar über x bzgl. ν , wobei die betreffenden Differentiationen und Integrationen vertausbar sind, d.h:

$$\int \frac{d}{d\theta} f(x; \theta) d\nu = \frac{d}{d\theta} \int f(x; \theta) d\nu = 0 \quad (2.1)$$

$$\int \frac{d^2}{d\theta^2} f(x; \theta) d\nu = \frac{d}{d\theta} \int \frac{d}{d\theta} f(x; \theta) d\nu = 0 \quad (2.2)$$

2.2 Fisher-Information

2.2.1 Score-Funktion

Score-Funktion $K(\theta; X)$ ist die wichtige Kenntnis in diesem Kapitel. Sie wird als die Grundlage der Definition von Fisher-Information angesehen. Die Score-Funktion ist eine Differentiation von einer logarithmische Dichtfunktion über den Parameter θ .

Die Score-Funktion einer Fisher-reguläre Verteilungsannahme $\mathfrak{B} = \{f(x; \theta) : \theta \in \Theta\}$ über einer Stichprobe $X = (X_1, \dots, X_n)$ für jedes $x \in C$ lautet:

$$K(\theta; x) := \frac{d}{d\theta} \log f(x; \theta) = \frac{d}{d\theta} f(x; \theta) / f(x; \theta) \quad (2.3)$$

Wir nennen $K(\theta; x)$ die Score-Funktion der Beobachtung x und $K(\theta; X)$ die Score-Funktion der Stichprobe X . Sie zeigt an, wie empfindlich die Dichte $f(x; \theta)$ von der Parameter θ abhängt.

Zunächst zeigen wir die Eigenschaften der Score-Funktion und beweisen wir die noch.

$$E_{\theta} K(\theta; X) = 0 \quad (2.4)$$

Beweis: $E_{\theta} K(\theta; X) = \int K(\theta; x) f(x; \theta) dv \stackrel{2.1}{=} \int \frac{d}{d\theta} f(x; \theta) dv$

$$\text{Var}_{\theta} K(\theta; X) = -E_{\theta} \frac{d}{d\theta} K(\theta; X) \quad (2.5)$$

Beweis: $\text{Var}_{\theta} K(\theta; X) = E_{\theta} [K(\theta; X)]^2 = \int \frac{d^2}{d\theta^2} f(x; \theta) dv - \frac{d}{d\theta} \int \frac{d}{d\theta} \log f(x; \theta) f(x; \theta) dv$

$$\stackrel{2.1}{2.4} - \int \frac{d^2}{d\theta^2} \log f(x; \theta) f(x; \theta) dv = E_{\theta} \frac{d}{d\theta} K(\theta; X)$$

[B.Rüger (1999)](Seite 93)

Aus dem Beweis erfahren wir, dass die Varianz von Score-Funktion ist eine negative Erwartungswert von Score-Funktion über θ .

2.2.2 Fisher-Information einer Stichprobe X

Zur Definition der Fisher-Information benügen wir eine zugrunde liegende Fisher-reguläre Verteilungsannahme $\mathfrak{B} = \{f(x; \theta) : \theta \in \Theta\}$ über X . Dann ist die Fisher-Information einer Beobachtung x definiert als:

$$I(\theta; x) := -\frac{d}{d\theta}K(\theta; x) = -\frac{d^2}{d\theta^2}\log f(x; \theta) \quad (2.6)$$

Wir berücksichtigen den Beweis von (2.5), die Fisher-Information einer Beobachtung x $I(\theta; x)$ ist nichts mehr als die negative Differentiation der Score-Funktion. $I(\theta; x)$ bekommen wir nach der Beobachtung der Stichprobe. Die Erwartungswert der Zufallsgröße $I(\theta; X)$ nennen wir die erwartete Fisher-Information $I_X(\theta)$ über θ oder einfach die Information von der Stichprobe X . Und die Fisher-Information $I_X(\theta)$ soll vor der Beobachtung erwartet werden (a priori Standpunkt). Eine Zusammenstellung von (2.4), (2.5) und (2.6) folgt:

$$I_X(\theta) = E_\theta I(\theta; X) = \text{Var}_\theta K(\theta; X) = E_\theta K^2(\theta; X) \quad (2.7)$$

[B.Rüger (1999)](Seite 93-94)

Wie oben erwähnt, die Score-Funktion $K(\theta; X)$ kann als ein Maß angesehen werden, wie gut man aufgrund einer Beobachtung x die verschiedenen Dichten lokal trennen kann. In diesem Fall, ist $I_X(\theta)$ als der Erwartungswert von $K^2(\theta; X)$ auch ein Maß dafür, wie gut man aufgrund einer beobachteten Stichprobe die Dichten lokal trennen kann. Wir wissen schon die Funktion der Fisher-Information, jedoch der Parameter θ als wahrer Wert, der wir bewerten sollen, unbekannt ist. Wir nehmen an, daß die Dichtfunktion $f(x; \theta)$ ein eindeutig bestimmtes Maximalstelle $\hat{\theta}$ für jede Beobachtung x besitzt. Durch der Logarithmierung der normierten Dichtfunktion $f(x; \theta)$ erhalten wir eine Gleichung:

$$k(\theta; x) = -\frac{1}{2}(\theta - \hat{\theta})^2 I(\hat{\theta}; x)$$

$k(\theta; x)$ hier stimmt eine Parabel von θ überein, die ihren Scheitel an der Stelle $\hat{\theta}$ und den Krümmungsradius $1/I(\hat{\theta}; x)$ hat. Für die Dichtfunktion bedeutet es: Je größer die Information $I(\hat{\theta}; x)$ ist, desto stärker ist die Parabel gekrümmt und desto schärfer und genauer ist die Maximalstelle $\hat{\theta}$.

Durch Rücktransformation auf $f(x; \theta)$ stellt eine approximative Verteilung dar:

$$f(x; \theta) \sim N(\hat{\theta}; 1/I(\hat{\theta}; x))$$

Die $\hat{\theta}$ ist der Erwartungswert der approximativen Verteilung und die Inverse der Fisher-Information $I(\hat{\theta}; x)$ ist die Varianz. In diesem Sinne erfassen wir, daß je größer die Fisher-Information ist, desto kleiner ist die Varianz der Verteilung und desto genauer ist die Schätzung $\hat{\theta}$ aus der Beobachtung x für das unbekannte θ .

2.2.3 Fisher-Information einer Statistik T

Nun gehen wir auf die Fisher-Information $I_T(\theta)$ einer Statistik $T = T(X)$ ein. Stellen wir eine Verteilungsfamilie $\mathfrak{B}^T = \{f_T(t; \theta)\}$ mit den Verteilungen von T dar, die durch das Bildmaß v^T dominiert werden. Aus der Fisher-Regularitätsbedingung der Verteilungsfamilie \mathfrak{B} kann man sagen, dass \mathfrak{B}^T auch Fisher-regulär ist. Mit der Dichtfunktion der Verteilung von T , folgt die Score-Funktion von $t = T(x)$:

$$K_T(\theta; t) = \frac{d}{d\theta} \log f_T(t; \theta) \quad (2.8)$$

Deshalb ist $K_T(\theta; T)$ die Score-Funktion von T über θ und vgl. (2.7):

$$I_T(\theta) = I_{T(x)}(\theta) = \text{Var}_\theta K_T(\theta; T) = E_\theta K_T^2(\theta; T) \quad (2.9)$$

[B.Rüger (1999)](Seite 96)

In diesem Abschnitt statt x setzen wir $T(X)$ ein, erhalten wir eine Abschätzung: $I_T(\theta) \leq I_X(\theta)$ für alle θ . Diese Abschätzung ist Teil von dem Hauptsatz über die Fisher-Information. Um diesen zu beweisen benötigen wir 4 besondere Aussagen.

Die erste Aussage betrifft die Vertauschbarkeitseigenschaften der Fisher-Regularität der Verteilungsfamilie \mathfrak{B} . Aber die Vertauschbarkeitsregeln gelten nicht nur für die Integrale über ganz \mathfrak{X} , sondern auch für die Integrale über irgendeine meßbare Teilmenge $B \subset \mathfrak{X}$. D.h. diese Vertauschbarkeitsregeln gelten auch für die Dichtfunktion $f_T(t; \theta)$ der Verteilungsfamilie \mathfrak{B}^T .

Die zweite Aussage betrifft die Score-Funktion von T und sie steht mit der Score-Funktion der Stichprobe X in folgende Beziehung dar:

$$K_T(\theta; t) = E_\theta[K(\theta; X)|T = t] \quad (2.10)$$

Die dritte Aussage mit der Hilfe des Satzes vom iterierten Erwartungswert folgt die Kovarianz der Score-Funktion $K(\theta; X)$ und $K_T(\theta; T)$ in die folgende Beziehung:

$$E_\theta[K(\theta; X)K_T(\theta; T(X))] = E_\theta[K_T^2(\theta; T(X))]$$

$$\text{cov}_\theta[K(\theta; X), K_T(\theta; T(X))] = I_{T(X)}(\theta) \quad (2.11)$$

Die vierte Aussage ist benötigen wir für Teil des Hauptsatzes und sie lautet:

$$I_X(\theta) - I_{T(X)}(\theta) = \text{Var}_\theta[K(\theta; X) - K_T(\theta; T(X))] \quad (2.12)$$

Für den Fall $I_{T(X)}(\theta) = I_x(\theta)$ für alle θ betrachten wir eine Ausnahme einer ν -Nullmenge N_θ von x . Und wenn die Ausnahmemenge N_θ unabhängig von θ ist, gilt die folgende Beziehung:

$$K(\theta; x) = K_T(\theta; T(x)) \text{ für alle } x \in \mathfrak{X} \setminus N \quad (2.13)$$

mit $\nu(N) = 0$ und $K(\theta; X) = K_T(\theta; T(X))$. [B.Rüger (1999)](Seite 97-98)

2.2.4 Hauptsatz der Fisher-Information

In diesem Abschnitt bezieht sich wieder auf eine Fisher-reguläre Verteilungsannahme \mathfrak{B} über die Stichprobe X mit einer Score-Funktion $K(\theta; X)$ und einer endlichen Fisher-Information. Dann wird die Fisher-Information $I_{T(X)}(\theta)$ durch den nachfolgenden Aussagen überprüft:

a) $I_T(\theta) \leq I_X(\theta)$ für alle θ .

Beweis: Von (2.15) wird den Hauptsatz a) folglich beweist.

b) Ist T suffizient für \mathfrak{B} , so gilt $I_{T(X)}(\theta) = I_X(\theta)$ für alle θ .

Die Aussage b) ist unter Bezugnahme auf die Charakterisierung der Suffizienz. Wir erklären hier kurz über den Begriff Suffizienz. Suffizienz heißt: für Auswertung der Beobachtung x einer Stichprobe X , x reduziert durch einer Stichprobefunktion $T(x)$, wenn

$T(x)$ keine Verlust an Information hat. D.h. mit einer suffizient Statistik T soll die Stichprobe X ohne Informationsverlust reduzieren. (vgl.[B.Rüger (1999)] Seite 38)

Beweis: Mit Hilfe des Satzes von Neyman-Kriterium, wenn T suffizient ist, haben die Dichtfunktionen $f(x; \theta)$ und $f_T(T(x); \theta)$ eine Beziehung in:

$$f(x; \theta) = h(x)f_T(T(x); \theta) \text{ mit } h(x) = \exp\{\tilde{h}(x)\}$$

Wenn wir die Score-Funktion von jeweiligen Dichtfunktionen rechnen, dann bekommen wir eine Gleichung: $K(\theta; x) = K_T(\theta; T(x))$. Mit den oben erwähnte Ausnahmemenge N_θ ist damit:

$$I_{T(X)}(\theta) = \text{Var}_\theta K(\theta; X) = \text{Var}_\theta K_T(\theta; T(X)) = I_X(\theta) \text{ für alle } \theta$$

c) Gilt $I_{T(X)}(\theta) = I_X(\theta)$ für alle θ und zusätzlich die Annahme (2.16), so ist T suffizient für \mathfrak{B} .

Beweis: Aus b) wissen wir, wenn T suffizient ist, dann ist $I_{T(X)}(\theta) = I_X(\theta)$. Andersherum ist $I_{T(X)}(\theta) = I_X(\theta)$, können wir auch schätzen, dass T suffizient ist. "Eine Statistik T ist genau dann suffizient, wenn ihre Score-Funktion mit derjenigen von X übereinstimmt.

Beispiel: Information in Bernoulli-Experiment.

Das Bernoulli-Experiment besitzt eine Verteilung der Stichprobe X : $f(x; p) = p^z(1 - p)^{n-z}$ mit $z = \sum x_i$. Die Score-Funktion der Beobachtung x lautet:

$$K(p; x) = \frac{z - np}{p(1 - p)}$$

Die Fisher-Information gilt:

$$I_X(p) = n/p(1 - p)$$

Wir nehmen eine suffizient Statistik Z und die Verteilung der Statistik Z lautet: $f_Z(z; p) = \binom{n}{z} p^z(1 - p)^{n-z}$. Nach dem Hauptsatz gilt: $I_Z(p) = I_X(p)$ für alle p gilt:

$$K_Z(p; z) = \frac{z - np}{p(1 - p)} = K(p; x)$$

Die Score-Funktion von Z mit derjenigen von X übereinstimmt.

"([B.Rüger (1999)],Seite 99-100)

2.2.5 Fisher-Information mit mehrere Statistiken

In diesem Abschnitt Beweisen wir die Fisher-Information über der Stichprobe X und mehreren Statistik $T_1(X)$, $T_2(X)$ und $V(X)$:

a) Ist V ancillary für \mathfrak{B} , so ist $I_V(\theta) = 0$ für all θ .

Beweis: Eine ancillary Statistik V für \mathfrak{B} heißt, die Verteilung von V nicht von θ abhängt. Die Statistik V allein enthält keine Information über θ . Sodass die Dichtfunktion $f_v(v; \theta)$ unabhängig von θ ist, gilt die Score-Funktion $K(\theta; v) \equiv 0$.

b)(Additivität der Information) Sind T_1 und T_2 unabhängig, so gilt:

$$I(T_1, T_2)(\theta) = I_{T_1}(\theta) + I_{T_2}(\theta) \quad (2.14)$$

Beweis: In diesem Fall sollen T_1 und T_2 unabhängig sein. Weil $\log(a \cdot b) = \log(a) + \log(b)$, führen wir die Addition der beiden unabhängigen Score-Funktionen ein:

$$K(T_1, T_2)(\theta; (t_1, t_2)) = K_{T_1}(\theta; t_1) + K_{T_2}(\theta; t_2)$$

Damit folgt die Information:

$$\begin{aligned} I_{(T_1, T_2)}(\theta) &= \text{Var}_\theta K_{(T_1, T_2)}(\theta; (t_1, t_2)) = \text{Var}_\theta K_{T_1}(\theta; t_1) + \text{Var}_\theta K_{T_2}(\theta; t_2) \\ &= I_{T_1}(\theta) + I_{T_2}(\theta) \end{aligned}$$

c) Ist $X = (X_1, \dots, X_n)$ eine i.i.d Stichprobe, so gilt für alle θ :

$$I_X(\theta) = nI_{X_1}(\theta) \quad (2.15)$$

Beweis: folgt aus b). [B.Rüger (1999)](Seite 101)

2.2.6 Fisher-Information mit speziellem Parameter

In diesem Abschnitt betrachten wir, dass die Fisher-Information auch von der speziellen Parameter γ der Fisher-reguläre Verteilungsfamilie \mathfrak{B} abhängt. Wir nehmen der Parameter $\gamma = \gamma(\theta)$ als eine Transformation an Stelle von θ an. In diesem Fall sind Parametern θ und $\gamma(\theta)$ äquivalent, obwohl die Information $\tilde{I}_X(\gamma) = \tilde{I}_X[\gamma(\theta)] \neq I_X(\theta)$. Die Beziehungen beiden Information soll mit einer nirgends verschwindenden Ableitung $\gamma'(\theta)$ folgen:

$$\begin{aligned}\tilde{I}_X[\gamma(\theta)] \cdot [\gamma'(\theta)]^2 &= \text{Var}_{\gamma}(\theta) \left[\frac{d}{d\gamma(\theta)} \log f(X; \gamma(\theta)) \cdot \gamma'(\theta) \right] \\ &= \text{Var}_{\theta} \left[\frac{d}{d\theta} \log f(X; \theta) \right] = I_X(\theta)\end{aligned}$$

[B.Rüger (1999)](Seite 101-102)

3 Informationsmatrix

Im letzten Kapitel haben wir die Information einer Fisher-reguläre Verteilungsannahme \mathfrak{B} über eine unbekannt Parameter θ erstellt. Im diesem Kapitel betrifft einer mehrdimensionaler Parametervektor $\theta = (\theta_1, \dots, \theta_r), r \geq 2$. Zu den Beweise der Aussagen in diesem Kapital bentigen wir teilweise von oben erwähnte Schritte.

3.1 Informationsmatrix

3.1.1 Fishersche Informationsmatrix einer Stichprobe

Wie obige Information einer Stichprobe X über Parameter θ benötige wir in diesem Kapitel auch einer voraussetzende Fisher-reguläre Verteilungsfamilie. Die Regularitätseigenschaften sollen sich in beiden Kapitale sehr nähre kommen. Sieht den Abschnitt 2.1. Nun gilt die Vertauschbarkeitsregeln auch für die Dichtfunktion $f(x; \theta)$ mit der betreffenden Parametervektor $\theta = (\theta_1, \dots, \theta_r), r \geq 2$. D.h. für $i = 1, \dots, r$ und $j = 1, \dots, r$ gilt die Vertauschbarkeitsregeln in folgenden Beziehungen:

$$\int \frac{\partial}{\partial \theta_i} f(x; \theta) dv = \frac{\partial}{\partial \theta_i} \int f(x; \theta) dv = 0 \quad (2.16)$$

$$\int \frac{\partial^2}{\partial \theta_i \partial \theta_j} f(x; \theta) dv = \frac{\partial}{\partial \theta_j} \int \frac{\partial}{\partial \theta_i} f(x; \theta) dv = 0 \quad (2.17)$$

Damit ist die r -dimensionale Score-Vektor $K(\theta; x)$ der Stichprobe X :

$$K(\theta; x) = (K_1(\theta; X), \dots, K_r(\theta; X)) \quad \text{mit} \quad (2.18)$$

$$K_i(\theta; x) = \frac{\partial}{\partial \theta_i} \log f(x; \theta), i = 1, \dots, r$$

Durch Kovarianz der Score-Funktion bekommen bekommen:

$$\text{cov}_\theta[K_i(\theta; X), K_j(\theta; X)] = -E_\theta \frac{\partial}{\partial \theta_i} K_j(\theta; X) = -E_\theta \frac{\partial^2}{\partial \theta_i \partial \theta_j} \log f(x; \theta) \quad (2.19)$$

Im Bezugnahme auf den ein-dimensionale Fall von (1.1) und (1.2) wird den nächste Schritt analog beweist. Wir nennen die Zufallsgröße $I(\theta; x)$ der symmetrischen $(r \times r)$ -Matrix die Fishersche-Informationsmatrix über der Beobachtung x über den Parameter θ .

$$I(\theta; x) = \left(-\frac{\partial^2}{\partial \theta_i \partial \theta_j} \log f(x; \theta) \right)_{i=1, \dots, r, j=1, \dots, r} \quad (2.20)$$

Der Erwartungswert dieser Matrix nennen wir die erwartete Fishersche-Informationsmatrix $I_X(\theta)$. Die bezieht sich auf die Situation vor der Beobachtung. Es folgt:

$$I_X(\theta) = E_\theta I(\theta; X) = \text{Cov}_\theta K(\theta; X) \quad (2.21)$$

[B.Rüger (1999)](Seite 104)

3.1.2 Fishersche Informationsmatrix einer Statistik

Für weitere Beweise einer Statistik $T = T(X)$ sollen analog wie oben sein.

Die r -dimensionale Score-Vektor der T mit $t = T(x)$ gilt:

$$K_T(\theta; t) = (K_{T;1}(\theta; t), \dots, K_{T;r}(\theta; t)) \quad \text{mit} \quad (2.22)$$

$$K_{T;i}(\theta; t) = \frac{\partial}{\partial \theta_i} \log f_T(t; \theta), \quad i = 1, \dots, r$$

Die Kovarianz der Score-Vektor und die Fisherscher Informationsmatrix von T stellt die Beziehung dar:

$$I_T(\theta) = I_{T(X)}(\theta) = \text{Cov}_\theta K_T(\theta; T) \quad (2.23)$$

Nach der Vergleichung der Informationsmatrizen $I_X(\theta)$ und $I_{T(X)}(\theta)$ folgt:

$$I_T(\theta) - I_{T(X)}(\theta) = \text{Cov}_\theta [K(\theta; X) - K_T(\theta; T(X))] \quad (2.24)$$

Mit eine Ausnahmemeenge vgl. analog Beweis aus Abschnitt 2.23 von (2.15) und (2.16)

setllen wir die Annahme dar:

$$K(\theta; x) = K_T(\theta; T(x)) \quad \text{für alle } x \in \mathfrak{X} \setminus N$$

[B.Rüger (1999)](Seite 105)

Der Hauptsatz der Fisher-Information bleibt auch für Informationsmatrix gültig. Hier werden die Aussagen und Beweisen verzichtet. Sieht Abschnitt 2.2.4.

Beispiel: Informationsmatrix im Gauß-Experiment.

Wir betrachten das Gauß-Experiment mit dem zweidimensionalen Parameter $\theta = (\mu, \sigma^2)$, wobei μ und σ^2 unbekannt sind, sodaß die Informationsmatrix eine (2×2) -Matrix ist. Die Dichte der Gauß-Experiment lautet: $f(x; \theta) = \left(\frac{1}{\sqrt{2\pi\sigma^2}}\right)^n \exp\left\{-\frac{1}{2\sigma^2} \sum (x_i - \mu)^2\right\}$. Die Score-Vektor gilt: $K(\theta; X) = (K_1(\theta; X), K_2(\theta; X))$ mit der Komponenten:

$$K_1(\theta; X) = \frac{\partial}{\partial \mu} \log f(X; \theta) = \frac{n}{\sigma^2} (\bar{X} - \mu) \quad \text{und}$$

$$K_2(\theta; X) = \frac{\partial}{\partial \sigma^2} \log f(X; \theta) = \frac{n}{2\sigma^4} (S_\mu^2 - \sigma^2)$$

Die Varianzen sind jeweils: $Var_\theta K_1(\theta; X) = \frac{n}{\sigma^2}$ und $Var_\theta K_2(\theta; X) = \frac{n}{2\sigma^4}$

Da \bar{X} und S^2 unabhängig sind, ist $cov_\theta(K_1(\theta; X), K_2(\theta; X)) = 0$.

Die Fishersche Informationsmatrix folgt: $I_X(\mu, \sigma^2) = \begin{pmatrix} n/\sigma^2 & 0 \\ 0 & n/2\sigma^4 \end{pmatrix}$

[B.Rüger (1999)](Seite 107)

Literaturverzeichnis

[B.Rüger (1999)] Dr. Bernhard Rüger, *Test- und Schätztheorie Band I: Grundlagen*.
R. Oldenbourg Verlag München Wien, 1999.