

Statistische Methoden der Datenanalyse

Wintersemester 2012/2013

Albert-Ludwigs-Universität Freiburg



Prof. Markus Schumacher, Dr. Stan Lai

Physikalisches Institut Westbau 2 OG

E-Mail: Markus.Schumacher@physik.uni-freiburg.de

stan.lai@cern.ch

http://terascale.physik.uni-freiburg.de/lehre/ws_1213/statmethoden_ws1213

Kapitel 3

Wahrscheinlichkeitsdichtefunktionen (Fortsetzung)

Multivariate WDF: mehrere Zufallsvariablen


Ergebnis des Experiment wird durch mehrere Observablenwerte charakterisiert, z.B. einen N -komponentigen Vektor: (x_1, \dots, x_n)

$$P(A \cap B) = \int f(x, y) dx dy$$

Gemeinsame WDF $f(x, y)$

$f(x, y) dx dy =$ Wahrscheinlichkeit, dass $x \in [x, x + dx]$ und $y \in [y, y + dy]$


Normierung:
$$\int \cdots \int f(x_1, \dots, x_n) dx_1 \cdots dx_n = 1$$



Marginal-WDF oder Randverteilung

Manchmal interessiert uns nur WDF für einige oder eine der Zuvallsvariablen:

$$\begin{aligned} P(A) &= \sum_i P(A \cap B_i) \\ &= \sum_i \int f(x, y_i) dy dx \\ &\rightarrow \int f(x, y) dy dx \end{aligned}$$



Integration über uninteressante ZV (“Marginalisieren”)
→ **Marginal-WDF oder Randverteilung**




$$f_1(x_1) = \int \cdots \int f(x_1, \dots, x_n) dx_2 \dots dx_n$$

$$f_x(x) = \int_{-\infty}^{\infty} f(x, y) dy$$

$$f_y(y) = \int_{-\infty}^{\infty} f(x, y) dx$$

x_1, x_2 sind unabhängig, genau dann wenn gilt $f(x_1, x_2) = f_1(x_1)f_2(x_2)$

Marginal-WDF oder Randverteilung



Marginal-WDF oder Randverteilung:
aus Projektion der gemeinsamen
WDF auf eine der ZV-Achsen

Bedingte WDF

Manchmal soll eine der Zufallsvariablen in der gemeinsamen WDF konstant gehalten werden.

Erinnerung an bedingte Wahrscheinlichkeit:

$$P(B|A) = \frac{P(A \cap B)}{P(A)} = \frac{f(x, y) dx dy}{f_x(x) dx}$$

→ bedingte WDF: $h(y|x) = \frac{f(x, y)}{f_x(x)}$, $g(x|y) = \frac{f(x, y)}{f_y(y)}$


Bayes-Theorem wird zu: $g(x|y) = \frac{h(y|x) f_x(x)}{f_y(y)}$.

Erinnerung: A, B unabhängig, wenn $P(A \cap B) = P(A)P(B)$.

→ x, y unabhängig wenn $f(x, y) = f_x(x) f_y(y)$.

Bedingte WDF (Fortsetzung)

Beispiel: : aus gemeinsamer WDF $f(x,y)$ werden bedingte WDFs $h(y|x_1)$, $h(y|x_2)$ bestimmt





$$\int h(y|x) dy = 1 .$$

- behandle eine der ZV als konstant in gemeinsamer WDF
- teile die gemeinsame WDF durch die Marginal-WDF der Variablen, die konstant gehalten werden
- was ist übrig bleibt ist bedingte WDF mit korrekter Normierung



Marginal- und Bedingte-WDF

2-dim.
gemeinsame
WDF



Rand-
verteilung
für y

Rand-
verteilung
für x



Bedingte
WDFs
für 2
Y-Werte


Funktionen / Transformation von Zufallsvariablen

Ein Funktion $a(x)$ von einer ZV x ist selbst ebenfalls eine Zufallsvariable.

Annahme: ZV x folgt einer WDF $f(x)$

Betrachte Abhängigkeit/Funktion: $x \rightarrow a(x)$.

Was ist die WDF für die ZV $g(a)$?



Sinnvolle Bedingung:

$$g(a) da = \int_{dS} f(x) dx$$

dS = Region im Raum der x -Werte für die a in $[a, a+da]$ liegt.

Transformation von Zufallsvariablen (II)

i) $a(x)$ eindeutig umkehrbar


Forderung:

Wahrscheinlichkeit, dass

a in $[a, a + da]$

= Wahrscheinlichkeit,

dass x in $[x(a), x(a + da)]$





Falls gilt $x(a) > x(a + da)$ wäre Integral $< 0 \rightarrow$ Betragsstriche

$$g(a)da = \left| \int_{x(a)}^{x(a+da)} f(x') dx' \right| = \int_{x(a)}^{x(a) + \left| \frac{dx}{da} \right| da} f(x') dx' = f(x(a)) \left| \frac{dx}{da} \right| da$$


Also gilt zusammengefasst:

$$g(a) = f(x(a)) \left| \frac{dx}{da} \right|$$


Transformation von Zufallsvariablen (III)



Wahrscheinlichkeit im a-Raum $g(a)da$
Entspricht der im x-Raum $f(x)dS$



Transformation von Zufallsvariablen (IV)



Transformation / Funktion: $a(x) = \exp(x)$

Wktdichtefunktion für ZV x : $f(x) = \frac{1}{2}x^2, x \text{ aus } [0, 2]$

Eindeutige Umkehrfunktion: $x(a) = \ln(a)$


Jakobifaktor / Differential: $\frac{dx}{da} = \frac{1}{a} > 0$

Und alles zusammengesetzt

$$g(a) = \frac{1}{2}(\ln(a))^2 \frac{1}{a} \quad \text{oder kompakt} \quad g(a) = \frac{\ln^2(a)}{2a}$$

Funktionen ohne eindeutige Umkehrung

Wenn es keine eindeutige Inverse von $a(x)$ gibt, dann summiere über alle dx -Intervalle in dS , die nach da abgebildet werden




Beispiel: $a = x^2, x = \pm\sqrt{a}, dx = \pm\frac{da}{2\sqrt{a}}$.

$$dS = \left[\sqrt{a}, \sqrt{a} + \frac{da}{2\sqrt{a}} \right] \cup \left[-\sqrt{a} - \frac{da}{2\sqrt{a}}, -\sqrt{a} \right]$$

$$g(a) = \frac{f(\sqrt{a})}{2\sqrt{a}} + \frac{f(-\sqrt{a})}{2\sqrt{a}}$$

Transformation von ZV: Mehrdeutige Inverse



Funktionen von mehreren Zufallsvariablen

Betrachte Zufallsvariablen $\vec{x} = (x_1, \dots, x_n)$

Und eine Funktion $a(\vec{x})$.

Die Bedingung der Gleichheit von Wahrscheinlichkeiten lautet:

$$g(a')da' = \int \dots \int_{dS} f(x_1, \dots, x_n) dx_1 \dots dx_n$$


Wobei dS = Region im x -Raum zwischen den Hyperflächen,
Die definiert werden durch

$$a(\vec{x}) = a', \quad a(\vec{x}) = a' + da'$$

Funktionen von mehreren ZV: Mellin-Faltung

Beispiel: ZV $x, y > 0$ mit gemeinsamer WDF $f(x, y)$,

Betrachte Funktion $z = xy$. Was ist $g(z)$?



$$\begin{aligned} g(z) dz &= \int \dots \int_{dS} f(x, y) dx dy \\ &= \int_0^\infty dx \int_{z/x}^{(z+dz)/x} f(x, y) dy \end{aligned}$$

$$\begin{aligned} \rightarrow g(z) &= \int_0^\infty f\left(x, \frac{z}{x}\right) \frac{dx}{x} \\ &= \int_0^\infty f\left(\frac{z}{y}, y\right) \frac{dy}{y} \end{aligned}$$

(Mellin-Faltung)

Funktionen von mehreren ZV: Fourier-Faltung

Beispiel: 2 unabhängige ZV x, y mit gemeinsamer WDF $f_x(x) f_y(y)$

Betrachte Funktion $a = x + y$. Was ist $g(a)$?

Anwendung: x Meßgröße, y Auflösungsvermögen des Messinstrumentes

$$\begin{aligned}g(a) da &= \int_{-\infty}^{\infty} \int_{(a-y)}^{(a-y+da)} f_x(x) f_y(y) dx dy \\ &= \int_{-\infty}^{\infty} f_x(a-y) f_y(y) da dy \\ \Rightarrow g(a) &= \int_{-\infty}^{\infty} f_x(a-y) f_y(y) dy\end{aligned}$$

(Fourier-Faltung)

Mehr zu Variablentransformationen

Betrachte eine Vektor von ZV $\vec{x} = (x_1, \dots, x_n)$ mit gemeinsamer WDF $f(\vec{x})$.

Bilde n linear unabhängige Funktionen $\vec{y}(\vec{x}) = (y_1(\vec{x}), \dots, y_n(\vec{x}))$

Für die, die inversen Funktionen existieren $x_1(\vec{y}), \dots, x_n(\vec{y})$

Dann ist die gemeinsame WDF für den Vektor der y -Funktionen gegeben durch

$$g(\vec{y}) = |J| f(\vec{x})$$

wobei J die
Jacobi-Determinante ist

$$J = \begin{vmatrix} \frac{\partial x_1}{\partial y_1} & \frac{\partial x_1}{\partial y_2} & \cdots & \frac{\partial x_1}{\partial y_n} \\ \frac{\partial x_2}{\partial y_1} & \frac{\partial x_2}{\partial y_2} & \cdots & \frac{\partial x_2}{\partial y_n} \\ \vdots & & & \vdots \\ \cdots & & & \frac{\partial x_n}{\partial y_n} \end{vmatrix}$$

Um z.B.. $g_1(y_1)$ zu erhalten, integriere (marginalisiere) über andere y in $g(\vec{y})$

Kovarianz und Korrelation

Definiere Kovarianz $\text{cov}[x,y]$ (oft auch Matrixnotation V_{xy}) als

$$\text{COV}[x, y] = E[xy] - \mu_x \mu_y = E[(x - \mu_x)(y - \mu_y)]$$

Korrelationskoeffizient (dimensionlos) definiert als

$$\rho_{xy} = \frac{\text{COV}[x, y]}{\sigma_x \sigma_y}$$

Wenn x, y , unabhängig, $f(x, y) = f_x(x)f_y(y)$, dann gilt



$$E[xy] = \int \int xy f(x, y) dx dy = \mu_x \mu_y$$

→ $\text{COV}[x, y] = 0$ x und y sind 'unkorreliert'

Bemerkung: Umkehrschluss i. a. nicht wahr.



Korrelation (Fortsetzung)

$$\rho = 0.75$$



$$\rho = -0.75$$

$$\rho = 0.95$$



$$\rho = 0.25$$

Fehlerfortpflanzung

Annahme: wir haben eine Stichprobe der ZV x $\vec{x} = (x_1, \dots, x_n)$

und wir kennen/schätzen die Kovarianzen

die die Messfehler in the x_i quantifizieren $V_{ij} = \text{COV}[x_i, x_j]$

Nun betrachten wir ein Funktion $y(\vec{x})$.

Frage: was ist die Varianz von $y(\vec{x})$?

- a) WDF $f(\vec{x})$ unbekannt
- b) WDF $f(\vec{x})$ bekannt \rightarrow "orthodoxe" Weg:
nutze gemeinsame WDF $f(\vec{x})$ um die WDF $g(y)$, zu bestimmen.
Dann bestimmte aus $g(y)$ die Varianz $V[y] = E[y^2] - (E[y])^2$.

Oft nicht praktikabel, $f(\vec{x})$ nicht vollständig bekannt.

Fehlerfortpflanzung (II)

Annahme: wir kennen: $\vec{\mu} = E[\vec{x}]$

In der Praxis nur Schätzwert aus der Stichprobe \vec{x}

Entwickle $y(\vec{x})$ in einer Taylor-Serie bis zum Glied erster Ordnung um $\vec{\mu}$

$$y(\vec{x}) \approx y(\vec{\mu}) + \sum_{i=1}^n \left[\frac{\partial y}{\partial x_i} \right]_{\vec{x}=\vec{\mu}} (x_i - \mu_i)$$

Um die Varianz $V[y]$ zu finden, brauchen wir $E[y^2]$ and $E[y]$.

$$E[y(\vec{x})] \approx y(\vec{\mu}) \quad \text{weil gilt} \quad E[x_i - \mu_i] = 0$$

Fehlerfortpflanzung (III)

$$\begin{aligned} E[y^2(\vec{x})] &\approx y^2(\vec{\mu}) + 2y(\vec{\mu}) \sum_{i=1}^n \left[\frac{\partial y}{\partial x_i} \right]_{\vec{x}=\vec{\mu}} E[x_i - \mu_i] \\ &+ E \left[\left(\sum_{i=1}^n \left[\frac{\partial y}{\partial x_i} \right]_{\vec{x}=\vec{\mu}} (x_i - \mu_i) \right) \left(\sum_{j=1}^n \left[\frac{\partial y}{\partial x_j} \right]_{\vec{x}=\vec{\mu}} (x_j - \mu_j) \right) \right] \\ &= y^2(\vec{\mu}) + \sum_{i,j=1}^n \left[\frac{\partial y}{\partial x_i} \frac{\partial y}{\partial x_j} \right]_{\vec{x}=\vec{\mu}} V_{ij} \end{aligned}$$

Zusammenfügen der Teilergebnisse liefert Varianz für $y(\vec{x})$

$$\sigma_y^2 \approx \sum_{i,j=1}^n \left[\frac{\partial y}{\partial x_i} \frac{\partial y}{\partial x_j} \right]_{\vec{x}=\vec{\mu}} V_{ij}$$

$$\mathbf{V}_y = \begin{pmatrix} \frac{\partial y}{\partial x_1} \\ \frac{\partial y}{\partial x_2} \\ \frac{\partial y}{\partial x_3} \\ \dots \\ \frac{\partial y}{\partial x_n} \end{pmatrix}^T \mathbf{V}_x \begin{pmatrix} \frac{\partial y}{\partial x_1} \\ \frac{\partial y}{\partial x_2} \\ \frac{\partial y}{\partial x_3} \\ \dots \\ \frac{\partial y}{\partial x_n} \end{pmatrix} = (\vec{\nabla} y)^t \mathbf{V}_x \vec{\nabla} y$$

Fehlerfortpflanzung (IV)

Wenn die x_i unkorreliert sind, i.e. $V_{ij} = \sigma_i^2 \delta_{ij}$, dann wird daraus

$$\sigma_y^2 \approx \sum_{i=1}^n \left[\frac{\partial y}{\partial x_i} \right]_{\vec{x}=\vec{\mu}}^2 \sigma_i^2$$

Ähnlich gilt für einen Satz von Funktionen $\vec{y}(\vec{x}) = (y_1(\vec{x}), \dots, y_m(\vec{x}))$

$$U_{kl} = \text{COV}[y_k, y_l] \approx \sum_{i,j=1}^n \left[\frac{\partial y_k}{\partial x_i} \frac{\partial y_l}{\partial x_j} \right]_{\vec{x}=\vec{\mu}} V_{ij}$$

Oder in Matrixnotation $U = AVA^T$, wobei

$$A_{ij} = \left[\frac{\partial y_i}{\partial x_j} \right]_{\vec{x}=\vec{\mu}}$$

Fehlerfortpflanzung (V): Beispiel 1

Betrachte Stichprobe der ZV x_i vom Umfang n .

Die unkorrelierten Messungen haben Messfehler: $\sigma^2 = \sigma_i^2$

Die Funktion $y(x_i)$ ist der Stichprobenmittelwert: $y(\bar{x}) = \bar{x} = \frac{1}{n} \sum_i^n x_i$

Was ist der Fehler auf den Stichprobenmittelwert?

Partielle Ableitungen: $\frac{\partial y}{\partial x_i} = \frac{1}{n}$

$$V(y) = V(\bar{x}) = \sum_i^n \left(\frac{\partial y}{\partial x_i}\right)^2 \sigma^2 = \frac{n}{n} \sigma^2 = \frac{\sigma^2}{n}$$

$$\sigma_{\bar{x}} = \frac{\sigma}{\sqrt{n}}$$



Fehlerfortpflanzung (VI)

Die 'Fehlerfortpflanzungsformel' sagt uns, wie wir die Kovarianzen eines Satzes von Funktionen $\vec{y}(\vec{x}) = (y_1(\vec{x}), \dots, y_m(\vec{x}))$ durch die Kovarianzen der ursprünglichen Variablen approximativ auswerten können.

Limitierung: exakt nur wenn $\vec{y}(\vec{x})$ linear.

Näherung bricht zusammen wenn die Funktion nicht linear ist in einem Bereich der vergleichbar ist mit der Größe von σ_x .

Bemerkung: keine Annahme über die WDF von x_j ,
i.e., sie muss nicht die Gaußverteilung sein



Fehlerfortpflanzung (VII) – Spezialfall

$$y = x_1 + x_2 \quad \rightarrow \quad \sigma_y^2 = \sigma_1^2 + \sigma_2^2 + 2\text{COV}[x_1, x_2]$$

$$y = x_1 x_2 \quad \rightarrow \quad \frac{\sigma_y^2}{y^2} = \frac{\sigma_1^2}{x_1^2} + \frac{\sigma_2^2}{x_2^2} + 2 \frac{\text{COV}[x_1, x_2]}{x_1 x_2}$$

wenn die x_i unkorreliert sind, gilt

addiere Fehler quadratisch für die Summe (oder Differenz),

addiere relative Fehler quadratisch für Produkt (oder Quotient).



Aber Korrelationen können dies komplett ändern...

Fehlerfortpflanzung (VIII) – Spezialfall (2)

Betrachte $y = x_1 - x_2$ mit

$$\mu_1 = \mu_2 = 10, \quad \sigma_1 = \sigma_2 = 1, \quad \rho = \frac{\text{COV}[x_1, x_2]}{\sigma_1 \sigma_2} = 0.$$

$$V[y] = 1^2 + 1^2 = 2, \rightarrow \sigma_y = 1.4$$

Nur nehmen wir an, dass $\rho = 1$. Dann gilt

$$V[y] = 1^2 + 1^2 - 2 = 0, \rightarrow \sigma_y = 0$$

i.e. für 100% Korrelation verschwindet der Fehler in der Differenz.

Analog: für die Summe werden die Fehler linear addiert

Fehlerfortpflanzung (IX): Beispiel 2

Betrachte Messung einer Spur/Trajektorie in Zylinderkoordinaten r, φ, z

Die Messfehler seien unkorreliert und es gelte $\sigma_r = 0, \sigma_\varphi, \sigma_z$

Die Kovarianzmatrix lautet dann:

$$V_{r,\varphi,z} = \begin{pmatrix} 0 & 0 & 0 \\ 0 & \sigma_\varphi^2 & 0 \\ 0 & 0 & \sigma_z^2 \end{pmatrix}$$

Wie sehen die Fehler in kartesischen Koordinaten aus?

$$x = r \cos \varphi$$

$$y = r \sin \varphi$$

$$z = z$$

Fehlerfortpflanzung (X): Beispiel 2

Die Jakobi-Matrix der Ableitungen lautet:

$$A = \begin{pmatrix} \cos \varphi & -r \sin \varphi & 0 \\ \sin \varphi & r \cos \varphi & 0 \\ 0 & 0 & 1 \end{pmatrix}$$

Die Kovarianzmatrix in x,y, z lautet:

$$V_{x,y,z} = AV_{r,\varphi,z}A^T = \begin{pmatrix} \sigma_\varphi^2 y^2 & -\sigma_\varphi^2 xy & 0 \\ -\sigma_\varphi^2 xy & \sigma_\varphi^2 x^2 & 0 \\ 0 & 0 & \sigma_z^2 \end{pmatrix}$$

Bem.: - Fehler auf z unverändert
- Fehler in x,y σ_x, σ_y
abhängig von x,y
korreliert

Die Korrelation ergibt sich zu: $\rho_{xy} = -\frac{\sigma_\varphi^2 x y}{\sigma_\varphi x \sigma_\varphi y} = -1$

Multinomialverteilung

Wie Binomial aber nun m verschiedene Ausgänge des anstelle von zwei,
Mit Wahrscheinlichkeiten für die einzelnen Ausgänge:

$$\vec{p} = (p_1, \dots, p_m), \quad \text{with } \sum_{i=1}^m p_i = 1 .$$

Für N Versuche suchen wir die Wahrscheinlichkeit das folgende Ergebnis zu erhalten:

$$\begin{aligned} n_1 & \text{ von Möglichkeit 1,} \\ n_2 & \text{ von Möglichkeit 2,} \\ & \dots \\ n_m & \text{ von Möglichkeit } m. \end{aligned}$$

Die Wktdichtefunktion ist die Multinomialverteilung für $\vec{n} = (n_1, \dots, n_m)$

$$f(\vec{n}; N, \vec{p}) = \frac{N!}{n_1! n_2! \dots n_m!} p_1^{n_1} p_2^{n_2} \dots p_m^{n_m}$$

Multinomialverteilung II

Nun betrachte Möglichkeit i as ‘Erfolg’, alle anderen als “Misserfolg”.

→ alle individuellen n_i binomialverteilt mit Parametern N, p_i

$$E[n_i] = Np_i, \quad V[n_i] = Np_i(1 - p_i) \quad \text{für alle } i$$

Für die Kovarianzen (i ungleich j) ergibt sich:

$$\begin{aligned} \text{cov}[n_i, n_j] &= E[(n_i - E[n_i])(n_j - E[n_j])] \\ &= E[n_i n_j] - E[n_i]E[n_j] \\ &= N(N - 1)p_i p_j - (Np_i)(Np_j) \\ &= -Np_i p_j. \end{aligned}$$

Negative Korrelation:
wenn in einer Klasse mehr
Ereignisse müssen
irgendwo welche fehlen

$$\rho_{n_i n_j} = \frac{\text{cov}[n_i, n_j]}{\sigma_{n_i} \sigma_{n_j}} = -\sqrt{\frac{p_i p_j}{(1 - p_i)(1 - p_j)}}.$$

Multinomialverteilung (III): Beispiele

$\vec{n} = (n_1, \dots, n_m)$ repräsentiert ein Histogramm

mit m bins, N (bekannt) Gesamteinträgen, alle Einträge unabhängig.

Zerfall eines instabilen Teilchens A: (1) $A \rightarrow BC$, (2) $A \rightarrow DE$, (3) $A \rightarrow FG$

Mit bekannten Zerfallswahrscheinlichkeiten für alle drei Modi.

(n_{BC}, n_{DE}, n_{FG}) folgte Multinomialverteilung.

Textanalyse: Auftreten der einzelnen Buchstaben des Alphabets.

(n_A, \dots, n_Z) folgt Multinomialverteilung.