

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

Anknüpfung an letzte Vorlesung

Axiomatische Definition:

For all $A \subset S, P(A) \geq 0$

$$P(S) = 1$$

If $A \cap B = \emptyset, P(A \cup B) = P(A) + P(B)$

bedingte Wahrscheinlichkeit:
 A gegeben B (mit $P(B) \neq 0$)

$$P(A|B) = \frac{P(A \cap B)}{P(B)}$$

Bayes-Theorem

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)}$$

Kapitel 3

Wahrscheinlichkeitsdichtefunktionen

Zufallsvariablen und Wkt.dichtefunktion

Eine Zufallsvariable (ZV) ist eine numerische Charakteristik, die einem Element der Grundgesamtheit zugeordnet wird.

ZV können diskret oder kontinuierlich sein.

Annahme: das Ergebnis eines Experimentes ist kontinuierliche ZV x
Wkt. Dafür, genau den Wert x_i zu messen ist beliebig klein.

Wahrscheinlichkeit x im Intervall $[x, x + dx]$ zu erhalten $= f(x)dx$.
 $\rightarrow f(x) =$ Wahrscheinlichkeitsdichtefunktion (WDF)

$$\int_{-\infty}^{\infty} f(x) dx = 1 \quad x \text{ muss irgendwo sein}$$

Für diskrete Zufallsvariable mit Ergebnissen x_i mit z.B. $i = 1, 2, \dots$

$$P(x_i) = p_i \quad \text{Wahrscheinlichkeits-Massenfunktion}$$

$$\sum_i P(x_i) = 1 \quad x \text{ muss einen der möglichen Werte annehmen}$$





Approximative WDF aus Histogramm

WDF = Histogramm mit
unendlich vielen Einträgen
(unendlich großes Sample),
und verschwindender (0) Binbreite
normiert auf "eins"

$$f(x) = \frac{N(x)}{n\Delta x}$$

n = number of entries

Δx = bin width





Kumulativverteilung

Wahrscheinlichkeit ein Ergebnis kleiner oder gleich x zu erhalten

$$\int_{-\infty}^x f(x') dx' \equiv F(x)$$

Kumulativverteilung



Alternativ kann WDF über $f(x) = \frac{\partial F(x)}{\partial x}$ definiert werden



Für diskrete ZV gilt $F(x) = \sum_{x_i \leq x} P(x_i)$

Quantile

Das Quantil x_α ist der Wert der ZV x für den die Wahrscheinlichkeit, dass die Messung einen Wert kleiner x_α ergibt gerade α ist.

$$F(x_\alpha) = \int_{-\infty}^{x_\alpha} f(x) dx = \alpha \Rightarrow x_\alpha = F^{-1}(\alpha)$$

Das Quantil zu $\alpha=0.5$ ist der Median $x_{1/2}$



Erwartungswerte

Betrachte kontinuierliche Zufallsvariable x with WDF $f(x)$.

Definiere den Erwartungswert (arithmetischen.Mittelwert) als

$$E[x] = \int x f(x) dx$$

Notation (meist): $E[x] = \mu$

Achtung:

$E[]$ ist keine Zufallsvariable, keine Funktion der Stichprobe

ist ein linearer Operator auf der Funktion z.B. $a(x)=x$

$$E[\alpha x + \beta] = \alpha E[x] + \beta$$

ist eine Charakteristik der Wahrscheinlichkeitsdichtefunktion

ist abhängig von den Parametern der WDF

Erwartungswerte

Für ein Funktion $y(x)$ with WDF $g(y)$, gilt

$$E[y] = \int y g(y) dy = \int y(x) f(x) dx \quad (\text{äquivalent})$$

n-tes algebraisches Moment (n=1 ergibt Mittelwert):

$$E[x^n] = \int_{-\infty}^{\infty} x^n f(x) dx = \mu'_n$$

n-tes zentrales Moment (n>1):

$$E[(x - \mu)^n] = \int_{-\infty}^{\infty} (x - \mu)^n f(x) dx = \mu_n$$

Erwartungswerte (II)


Varianz = 2tes zentrales Moment:

$$V[x] = E[(x - \mu)^2] = \int_{-\infty}^{\infty} (x - \mu)^2 f(x) dx \quad V[x] = \sigma^2$$

$$V[x] = E[(x - \mu)^2] = E[x^2] - 2E[x]\mu + \mu^2 = E[x^2] - \mu^2.$$

Standardabweichung: $\sigma = \sqrt{\sigma^2}$

$$\sigma_x = \sqrt{V[x]}$$



Erwartungswerte (III)

Weitere zentrale Momente (selten gebraucht):

$$\text{Schiefe } \gamma = \mu_3 / \sigma^3$$

misst Asymmetrie der Verteilung:
positiv (negativ) für Ausläufer nach rechts (links)

$$\text{Wölbung oder Kurtosis } \kappa = \mu_4 / \sigma^4 - 3$$

misst Anteil im Zentrum zum Anteil in Ausläufern
relativ zur Gauss-/Normalverteilung

0: für Gaussverteilung

positiv: für mehr Ausläufer als Gaussverteilung bei gleicher Varianz

negativ: für weniger Ausläufer als Gaussverteilung bei gleicher Varianz

Erwartungswerte (IV)



Schiefe $\gamma = \mu_3 / \sigma^3$

$$\begin{aligned}\gamma_1 &= E[(x - \mu)^3] / \sigma^3 \\ &= E[x^3 - 3\mu x^2 + 3\mu^2 x - \mu^3] / \sigma^3 \\ &= \{E(x^3) - 3\mu[E(x^2) - \mu E(x)] - \mu^3\} / \sigma^3 \\ &= \frac{E(x^3) - 3\mu\sigma^2 - \mu^3}{\sigma^3}.\end{aligned}$$

Wölbung oder Kurtosis $\kappa =$

$$\mu_4 / \sigma^4 - 3$$

Alle Verteilungen haben
Mittelwert = 0 und Varianz = 1



Binomial-Verteilung

Betrachte N unabhängige Messungen/Experimente (Bernoulli-Versuche):

Ausgang jedes Experimentes ist entweder "Erfolg" oder "Misserfolg"

Die Wahrscheinlichkeit für Erfolg (Misserfolg) sind p ($1-p$)

Definiere diskrete ZV als Anzahl der Erfolge n ($0 \leq n \leq N$).

Wkt. für eine spezielle Reihenfolge von n Erfolgen und $(N-n)$ Misserfolgen ist:

$$p p (1 - p) p (1 - p) = p^n (1 - p)^{N-n}$$

Aber Anordnung ist unwichtig \rightarrow Kombinatorik es gibt $\frac{N!}{n!(N-n)!}$

Möglichkeiten (Permutationen) n Erfolge in N Versuchen einzuordnen.

Geamtwkt. für n Erfolge ist die Summe der Wkt. für jede Permutation.

Binomial-Verteilung (2)

Die Binomialverteilung lautet:

$$f(n; N, p) = \frac{N!}{n!(N-n)!} p^n (1-p)^{N-n}$$

Zufalls-
variable

Parameter







Für den Erwartungswert und die Varianz findet man:

$$E[n] = \sum_{n=0}^N n f(n; N, p) = Np \quad V[n] = E[n^2] - (E[n])^2 = Np(1-p)$$

Die charakteristische Funktion lautet: $\varphi_n(k; p, N) = (p(\exp(ik) - 1) + 1)^N$

Binomial-Verteilung (3)

Verteilungen für verschiedene Parameter p und Anzahl der Versuche N :



Binomial-Verteilung: Beispiele

Nachweis eines Objektes mit Detektor

Ansprechwahrscheinlichkeit eines Detektors $p=0.95$

Bedingung: mindestens Treffer in drei Detektorlagen für Rekonstruktion der Spur

Frage: wieviel Kammern werden benötigt um $>99\%$ effizient zu sein?

3 Kammern: $P(k=3;0.95,3) = 0.95^3 = 0.857$

4 Kammern: $P(k \geq 3;0.95,4) = 0.171 + 0.815 = 0.986$

5 Kammern: $P(k \geq 3;0.95,5) = 0.021 + 0.204 + 0.774 = 0.999$

Wahrscheinlichkeit für Erfolg p

Wieviele Versuche damit mindestens 1 Erfolg mit Wkt $\geq \alpha$?

$P(k \geq 1; p, n) \geq \alpha$ oder $1 - P(K=0; p, n) \geq \alpha$

$P(k=0) \leq 1 - \alpha$

$(1-p)^N \leq 1 - \alpha$

$N \geq \ln(1 - \alpha) / \ln(1 - p)$

Binomial-Verteilung: Beweise

Normierung:

$$\begin{aligned}\sum_{n=0}^N f(n; N, p) &= \sum_{n=0}^N \frac{N!}{n!(N-n)!} p^n (1-p)^{N-n} \\ &= (p + (1-p))^N \\ &= 1.\end{aligned}$$

Erwartungswert: $E[n]$

$$\begin{aligned}E[n] &= \sum_{n=0}^N n \frac{N!}{n!(N-n)!} p^n (1-p)^{N-n} \\ &= \sum_{n=1}^N n \frac{N!}{n!(N-n)!} p^n (1-p)^{N-n} \\ &= Np \sum_{n=1}^N \frac{(N-1)!}{(n-1)!((N-1)-(n-1))!} p^{(n-1)} (1-p)^{(N-1)-(n-1)} \\ &= Np \sum_{n=0}^{N-1} \frac{(N-1)!}{(n)!((N-1)-(n))!} p^n (1-p)^{(N-1)-n} \\ &= Np\end{aligned}$$

Poissonverteilung (i)

Betrachte Grenzfall der Binomialverteilung mit

$$N \rightarrow \infty, \quad p \rightarrow 0, \quad E[n] = Np \rightarrow \nu . \quad \text{konstant}$$




→ n folgt der Poissonverteilung:

$$f(n; \nu) = \frac{\nu^n}{n!} e^{-\nu} \quad (n \geq 0)$$

$$E[n] = \nu, \quad V[n] = \nu .$$

Example: number of scattering events n with cross section σ found for a fixed integrated luminosity, with

$$\nu = \sigma \int L dt .$$



Poissonverteilung: Herleitung 1

Betrachte Grenzfall der Binomialverteilung mit

$$N \rightarrow \infty, \quad p \rightarrow 0, \quad E[n] = Np \rightarrow \nu \text{ . konstant}$$

→ n folgt der Poissonverteilung:

$$f(n; \nu) = \frac{\nu^n}{n!} e^{-\nu} \quad (n \geq 0)$$

$$E[n] = \sum_{n=0}^{\infty} n \frac{\lambda^n}{n!} \exp(-\lambda) = \lambda,$$

$$V[n] = \sum_{n=0}^{\infty} (n - \lambda)^2 \frac{\lambda^n}{n!} \exp(-\lambda) = \lambda.$$

