


Anpassungsrechnungen mit kleinsten Quadraten und Maximum Likelihood

KARLSRUHER INSTITUT FÜR TECHNOLOGIE (KIT)



Einleitung

Grundlagen

Wahrscheinlichkeit

Eigenschaften von Schätzern

Maximum-Likelihood-Methode

Prinzip

Beispiel

Fehlerberechnung

Eigenschaften

Methode der kleinsten Quadrate

Prinzip

Zusammenhang mit Maximum-Likelihood

Lineare Kleinste Quadrate und Fehlerfortpflanzung

χ^2 -Test

Eigenschaften

Zusammenfassung

0.5159 6.1404 0.0409 0.004181
1.2335 0.3405 0.0819 0.004434
2.0768 0.0963 0.1228 0.004827
3.0872 0.0525 0.1637 0.005328
4.0816 0.0294 0.2046 0.005910
4.8890 0.0188 0.2456 0.006552
5.5414 0.0161 0.2865 0.007237
6.0929 0.0123 0.3274 0.007955
6.5342 0.0123 0.3684 0.008698
6.8709 0.0122 0.4093 0.009459
7.1006 0.0086 0.4502 0.010234
7.2838 0.0085 0.4912 0.011021
7.3960 0.0080 0.5321 0.011817
7.4743 0.0069 0.5730 0.012620
7.4906 0.0067 0.6139 0.013430
7.4860 0.0064 0.6549 0.014244
7.4650 0.0080 0.6958 0.015063
7.4396 0.0063 0.7367 0.015885

- Man hat viele Daten
- Die Theorie hat wenige Parameter
- Parameter müssen so angepasst werden, dass sie gut zu den Daten passen

Anpassungsrechnung (auch Parameterschätzung, Parameteranpassung, Ausgleichsrechnung, Fitting) mit

- Maximum-Likelihood-Methode
- Methode der kleinsten Quadrate

Wahrscheinlichkeitsverteilung

Eine Wahrscheinlichkeitsverteilung kann

- diskret (Bsp. Würfel, Spin) oder
- kontinuierlich

sein.

Definition

Wahrscheinlichkeitsdichtefunktion (probability density function, pdf)

$$P(a < x < b) = \int_a^b f(x) dx$$

mit

$$\int_{-\infty}^{\infty} f(x) dx = 1$$

Definition

Erwartungswert einer Funktion $h(x)$:

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

Definition

Erwartungswert einer Funktion $h(x)$:

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

Definition

Mittelwert=Erwartungswert von x

$$\langle x \rangle = E[x] = \int_{-\infty}^{\infty} xf(x) dx$$

Definition

Varianz von x :

$$V[x] = E[(x - \langle x \rangle)^2] = E[x^2] - E[x]^2$$

Definition

Varianz von x :

$$V[x] = E[(x - \langle x \rangle)^2] = E[x^2] - E[x]^2$$

Definition

Kovarianz von x und y :

$$\text{cov}[x, y] = E[(x - \langle x \rangle)(y - \langle y \rangle)] = E[x \cdot y] - E[x]E[y]$$

Definition

Kovarianzmatrix:

$$\mathbf{V}[\mathbf{x}] = E[(\mathbf{x} - \langle \mathbf{x} \rangle)(\mathbf{x} - \langle \mathbf{x} \rangle)^T]$$

$$\mathbf{V} = \begin{pmatrix} \text{COV}(x_1, x_1) & \text{COV}(x_1, x_2) & \dots & \text{COV}(x_1, x_n) \\ \text{COV}(x_2, x_1) & \text{COV}(x_2, x_2) & \dots & \text{COV}(x_2, x_n) \\ \vdots & \vdots & & \vdots \\ \text{COV}(x_n, x_1) & \text{COV}(x_n, x_2) & \dots & \text{COV}(x_n, x_n) \end{pmatrix}$$

S sei die Summe aus N unabhängigen Zufallsvariablen mit Mittelwert a_i und Varianz V_j . Dann gilt:

- $E[S] = \sum_{i=1}^N a_i$
- $V[S] = \sum_{i=1}^N V_i$
- Für $N \rightarrow \infty$ ist die pdf von S eine Normalverteilung

Eigenschaften von Schätzern

Ein Schätzer sollte folgende Eigenschaften haben:

- Konsistenz
- Erwartungstreue
- Effizienz
- Robustheit

Effizienz und Robustheit stehen oft in Widerspruch zueinander.

- Benötigte Rechenleistung sollte gering sein

Ein Schätzer sollte folgende Eigenschaften haben:

- Konsistenz: $\lim_{N \rightarrow \infty} \hat{a} = a_0$
- Erwartungstreue
- Effizienz
- Robustheit

Effizienz und Robustheit stehen oft in Widerspruch zueinander.

- Benötigte Rechenleistung sollte gering sein

Ein Schätzer sollte folgende Eigenschaften haben:

- Konsistenz: $\lim_{N \rightarrow \infty} \hat{a} = a_0$
- Erwartungstreue: $E[\hat{a}] = a_0$
- Effizienz
- Robustheit

Effizienz und Robustheit stehen oft in Widerspruch zueinander.

- Benötigte Rechenleistung sollte gering sein

Ein Schätzer sollte folgende Eigenschaften haben:

- Konsistenz: $\lim_{N \rightarrow \infty} \hat{a} = a_0$
- Erwartungstreue: $E[\hat{a}] = a_0$
- Effizienz: $V[\hat{a}]$ sollte minimal sein
- Robustheit

Effizienz und Robustheit stehen oft in Widerspruch zueinander.

- Benötigte Rechenleistung sollte gering sein

Ein Schätzer sollte folgende Eigenschaften haben:

- Konsistenz: $\lim_{N \rightarrow \infty} \hat{a} = a_0$
 - Erwartungstreue: $E[\hat{a}] = a_0$
 - Effizienz: $V[\hat{a}]$ sollte minimal sein
 - Robustheit: Kein Einfluss von falschen Daten/Voraussetzungen
- Effizienz und Robustheit stehen oft in Widerspruch zueinander.
- Benötigte Rechenleistung sollte gering sein

Definition


Likelihood-Funktion

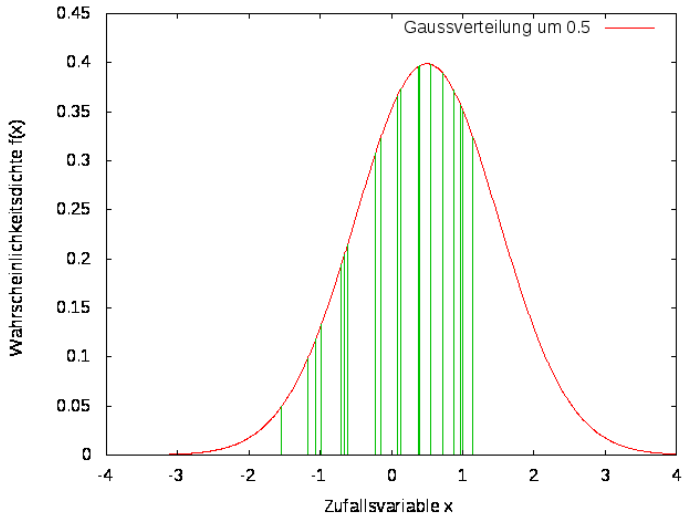
$$L(\mathbf{a}) = \prod_i f(x_i, \mathbf{a})$$

beschreibt die Wahrscheinlichkeit die Messwerte $\{x_i\}$ zu erhalten.

- Maximum-Likelihood-Methode: Maximierung der Likelihood-Funktion
- Praktisch meist Minimierung der negative Log-Likelihood-Funktion:

$$F(\mathbf{a}) = -\ln L(\mathbf{a}) = -\sum_i \ln f(x_i, \mathbf{a})$$





Einfaches Beispiel


Lebensdauer

$$f(t, \gamma) = \gamma e^{-\gamma t} \quad \text{mit } \gamma = \frac{1}{\tau}$$

$$F(\gamma) = -N \cdot \ln(\gamma) + \sum_{i=1}^N \gamma t_i$$

$$\frac{d}{d\gamma} F(\gamma) = -\frac{N}{\gamma} + \sum_{i=1}^N t_i \stackrel{!}{=} 0$$

$$\hat{\tau} = \frac{1}{\hat{\gamma}} = \sum_{i=1}^N \frac{t_i}{N}$$



Einfaches Beispiel

Lebensdauer

Angenommen es kann nur im
Zeitintervall $0 < t < t_{max}$ gemessen werden.


$$f(t, \gamma) = \frac{\gamma e^{-\gamma t}}{1 - e^{-\gamma t_{max}}}$$

$$F(\gamma) = N \left[\ln \left(1 - e^{-\gamma t_{max}} \right) - \ln(\gamma) \right] + \sum_{i=1}^N \gamma t_i$$

⋮

$$\hat{t} = \sum_{i=1}^N \frac{t_i}{N} + \frac{t_{max} \exp(-t_{max} / \hat{t})}{1 - \exp(-t_{max} / \hat{t})}$$

Dies ist nur numerisch auswertbar.



Bei großen Proben ist die Fehlerzuordnung einfach:

- Nach dem Zentralen Grenzwertsatz geht die Likelihood-Funktion gegen eine Gauß-Funktion, bei großen Stichproben.


- Entwicklung:

$$F(a) = F(\hat{a}) + \frac{1}{2} \cdot \frac{d^2 F}{da^2} \cdot (\hat{a} - a)^2 + \mathcal{O}(a^3)$$

- Vergleich

mit Gauß: $-\ln(\text{Gauß}) = \text{const} + \frac{1}{2} \frac{(\hat{a}-a)^2}{\sigma^2}$

- $\Rightarrow F(\hat{a} \pm r \cdot \sigma) = F(\hat{a}) + \frac{r^2}{2}$




Fehlerberechnung

Allgemeiner Fall

Es können asymmetrische Konfidenzgrenzen definiert werden:

- $F(\hat{a} + r \cdot \sigma_+) = F(\hat{a}) + \frac{r^2}{2}$
- $F(\hat{a} - r \cdot \sigma_-) = F(\hat{a}) + \frac{r^2}{2}$



Eigenschaften der Maximum-Likelihood-Methode

- Schätzer ist invariant unter Parameter-Transformation: $\hat{g}(a) = g(\hat{a})$
- Normalerweise konsistent
- Nicht immer erwartungstreu
- Erwartungstreu für $N \rightarrow \infty$
- Effizienteste Methode
- Nicht robust, da Wahrscheinlichkeitsdichte exakt bekannt sein muss
- Kann hohe Rechenleistung erfordern

Definition


$$S = \sum_{i=1}^N \frac{(y_i - a_i)^2}{\sigma_i^2} = \sum_{i=1}^N \frac{\Delta y_i^2}{\sigma_i^2}$$

- N Messwerte y_i mit Varianz σ_i^2
- a_i aus Theorie
- Δy_i heißen Residuen
- Methode der kleinsten Quadrate: Minimiere S
- Allgemeiner Fall mit Kovarianzmatrix \mathbf{V} und $\Delta \mathbf{y} =$


$$\begin{pmatrix} \Delta y_1 \\ \Delta y_2 \\ \vdots \\ \Delta y_N \end{pmatrix}$$

$$S = \Delta \mathbf{y}^T \mathbf{V}^{-1} \Delta \mathbf{y}$$

Methode der kleinsten Quadrate



Methode der kleinsten Quadrate



Zusammenhang von Maximum-Likelihood und Kleinste Quadrate

negative log-Likelihood für gaußsche Wahrscheinlichkeitsdichte.

$$\begin{aligned} F(a) &= - \sum_i \ln \left(\frac{1}{\sigma\sqrt{2\pi}} e^{-\frac{1}{2} \frac{(x_i - a)^2}{\sigma^2}} \right) \\ &= \text{const} + \frac{1}{2} \sum_i \frac{(x_i - a)^2}{\sigma^2} \\ &= \text{const} + \frac{1}{2} S(a) \end{aligned}$$

- Lineare Theorie $t(x|\mathbf{a}) = \sum_i a_i t_i(x)$
- Zur Vereinfachung gleiche Varianzen
- $S = \frac{1}{\sigma^2} \sum_i (y_i - t(x_i))^2$
- $\frac{\partial S}{\partial a_j} = -\frac{2}{\sigma^2} \sum_i t_j(x_i)(y_i - t(x_i)) \stackrel{!}{=} 0$
- Normalengleichung: $\sum_i t_j(x_i) \sum_k \hat{a}_k t_k(x_i) = \sum_i y_i t_j(x_i)$

■ Matrixschreibweise

$$\mathbf{A} = \begin{pmatrix} t_1(x_1) & t_2(x_1) & \dots & t_p(x_1) \\ t_1(x_2) & t_2(x_2) & \dots & t_p(x_2) \\ \vdots & & & \vdots \\ t_1(x_n) & t_2(x_n) & \dots & t_p(x_n) \end{pmatrix}$$

$$\mathbf{a} = \begin{pmatrix} a_1 \\ a_2 \\ \vdots \\ a_p \end{pmatrix} \quad \mathbf{y} = \begin{pmatrix} y_1 \\ y_2 \\ \vdots \\ y_n \end{pmatrix}$$

■ Normalengleichung: $(\mathbf{A}^T \mathbf{A}) \hat{\mathbf{a}} = \mathbf{A}^T \mathbf{y}$

$$\hat{\mathbf{a}} = (\mathbf{A}^T \mathbf{A})^{-1} \mathbf{A}^T \mathbf{y}$$

- Allgemeine Lösung mit Gewichtsmatrix $\mathbf{W} = \mathbf{V}^{-1}$:

$$\hat{\mathbf{a}} = (\mathbf{A}^T \mathbf{W} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{W} \mathbf{y} = \mathbf{B} \mathbf{y}$$

- Fehlerfortpflanzung:


$$\mathbf{V}_a = \mathbf{B} \mathbf{y} \mathbf{B}^T$$

$$\mathbf{V}_a = (\mathbf{A}^T \mathbf{W} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{W} \mathbf{V} \left((\mathbf{A}^T \mathbf{W} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{W} \right)^T$$

$$\mathbf{V}_a = (\mathbf{A}^T \mathbf{W} \mathbf{A})^{-1} \mathbf{A}^T \mathbf{W} \mathbf{A} (\mathbf{A}^T \mathbf{W} \mathbf{A})^{-1}$$


$$\mathbf{V}_a = (\mathbf{A}^T \mathbf{W} \mathbf{A})^{-1}$$

- χ_k^2 -Verteilung gibt die Wahrscheinlichkeitsdichte für die Summe der Quadrate von k standard-normalverteilten Zufallsvariablen (k Freiheitsgrade) an.
- Für gaußsche Fehler folgt S einer χ^2 Verteilung mit $n - p$ Freiheitsgraden.
- Wahrscheinlichkeit den Wert S oder größeren zu bekommen:
$$\int_S^\infty f(\chi^2) d\chi^2$$
- Wenn diese Wahrscheinlichkeit zu klein ist (z.B 1%), dann wird die Theorie verworfen.



- Es gibt analytische Lösung
- Konsistent und erwartungstreu, wenn Daten unverzerrt sind
- Effizienteste lineare erwartungstreu Methode
- Nicht Robust, wegen Ausreißern in den Daten
- Benötigte Rechenleistung eher gering
- Bei gaußschen Fehlern Fit-Qualität mit χ^2

- Es gibt analytische Lösung
- Konsistent und erwartungstreu, wenn Daten unverzerrt sind
- Effizienteste lineare erwartungstreu Methode
- Nicht Robust, wegen Ausreißern in den Daten
- Benötigte Rechenleistung eher gering
- Bei gaußschen Fehlern Fit-Qualität mit χ^2



	Maximum-Likelihood	Kleinste Quadrate
Voraussetzung	pdf exakt bekannt	Mittelwerte und Varianzen
Konsistent	Ja	Ja
Erwartungstreu	Nur asymptotisch	Im linearen Fall
Effizient	maximal	maximal
Robust	Nein (pdf muss exakt bekannt sein)	Nein (Ausreißer)
Rechenaufwand	kann sehr hoch werden	im linearen Fall gering
Fit-Qualität	nein	bei gaußschen Fehlern

Gleich bei gaußschen Fehlern

- Volker Blobel, Erich Lohrmann: *Statistische und numerische Methoden der Datenanalyse*
- Gerhard Bohm, Günter Zech: *Einführung in Statistik und Messwertanalyse für Physiker*
<http://www-library.desy.de/preparch/books/vstatmp.pdf>
- Roger Barlow: *Statistics: A Guide to the Use of Statistical Methods in the Physical Sciences*