



Varianzkomponentenschätzung

Peter von Rohr

Multiple Lineare Regression

Annahmen

- Modell

$$\mathbf{y} = \mathbf{X}\mathbf{b} + \mathbf{e}$$

- Varianz der Fehler e_i ist konstant, d.h. $\text{Var}(e_i) = \sigma^2$ für alle i
- Fehler e_i sind nicht korreliert, d.h. $\text{Cov}(e_i, e_j) = 0$ für $i \neq j$
- Fehler \mathbf{e} ist multivariat normal verteilt

Momente

- Erwartungswerte: $E[\mathbf{e}] = \mathbf{0}$, $E[\mathbf{y}] = \mathbf{X}\mathbf{b}$
- Varianzen: $\text{Var}(y_i) = \sigma^2$, $\text{Var}(e_i) = \sigma^2$ für alle i

Parameterschätzung

- Im linearen Model $\mathbf{y} = \mathbf{X}\mathbf{b} + \mathbf{e}$ sind \mathbf{b} und σ^2 unbekannte Parameter
- Parameter sollen als Funktion der Daten (\mathbf{y}) geschätzt werden
- Ein möglicher Schätzer $\hat{\mathbf{b}}_{LS}$ für \mathbf{b} kann mit **Least Squares** (kleinste Quadrate) berechnet werden

$$\hat{\mathbf{b}}_{LS} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}$$

- **Aber** Least Squares gibt keine Schätzung für σ^2

Schätzung der Varianzkomponente σ^2

Eine Beobachtung betreffend der Eigenschaft der **Erwartungstreue** (Unbiasedness) eines Schätzers führt zu folgendem Ergebnis

- Erwartungstreue (Unbiasedness) ist eine Eigenschaft eines Schätzers $\hat{\theta}$ für einen Parameter θ , sofern gilt, dass $E[\hat{\theta}] = \theta$
- Erwartungswert der Summe der quadrierten Residuen (r_i)

$$\begin{aligned} E\left[\sum_{i=1}^n r_i^2\right] &= \sum_{i=1}^n E[r_i^2] = \sum_{i=1}^n \text{Var}(r_i) = \sigma^2 \sum_{i=1}^n (1 - P_{ii}) \\ &= \sigma^2(n - \text{tr}(P)) = \sigma^2(n - p) \end{aligned}$$

wobei: $r_i = y_i - \hat{y}_i = y_i - \mathbf{x}_i^T \hat{\mathbf{b}}$ und Matrix $\mathbf{P} = \mathbf{X}(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T$,
 n : Anzahl Beobachtungen und p : Anzahl Parameter

Schätzung der Varianzkomponente σ^2 II

- Somit gilt Erwartungstreue für den Schätzer

$$\hat{\sigma}^2 = \frac{1}{(n-p)} \sum_{i=1}^n r_i^2$$

- da für die Erwartungswerte gilt

$$\begin{aligned} E[\hat{\sigma}^2] &= E\left[\frac{1}{(n-p)} \sum_{i=1}^n r_i^2\right] = \frac{1}{(n-p)} E\left[\sum_{i=1}^n r_i^2\right] \\ &= \frac{1}{(n-p)} [\sigma^2(n-p)] = \sigma^2 \end{aligned}$$

- Dieser Schätzer wird oft als LS-Schätzer bezeichnet

Varianzanalyse - ANOVA

- Effekte oder Faktoren im Modell (bis jetzt x Variable) sind kategorisch oder qualitativ
- Ziel ist es herauszufinden, wie viel von der totalen empirischen Varianz in den Beobachtungen durch die Faktoren erklärt werden kann.
- Folgendes Modell wird angenommen:

$$y_{ij} = \mu + \alpha_i + e_{ij}$$

wobei: Faktor α $i = 1, \dots, I$ Stufen aufweist und $j = 1, \dots, J_i$ Beobachtungen pro Stufe vorliegen.

- Effekte sind nur unter gewissen Restriktionen schätzbar. Häufig wird die Summe aller Effekte $\sum_i J_i \alpha_i = 0$ gesetzt

Parameterschätzung ANOVA

- Mit Restriktion $\sum_i J_i \alpha_i = 0$ folgen Schätzer

$$\hat{\mu} = \bar{y} \text{ und } \hat{\alpha}_i = \bar{y}_{i.} - \bar{y}$$

wobei: \bar{y} der Mittelwert über alle Beobachtungen und $\bar{y}_{i.}$ der Mittelwert über alle Beobachtungen auf Stufe i ist.

- Die Varianzanteile werden aufgrund der Summenquadrate bestimmt

Tabelle der Varianzanalyse - ANOVA Table

Quelle	DF	SQ	MSQ	F	P
Faktor α	$i - 1$	SQZ	MSQZ	MSQZ/MSQE	
Fehler e	$n - i$	SQE	MSQE		
Total	$n - 1$	SQT			

wobei

$$SQT = \sum_{i=1}^I \sum_{j=1}^{J_i} (y_{ij} - \bar{y})^2$$

$$SQZ = \sum_{i=1}^I \sum_{j=1}^{J_i} (\bar{y}_{i.} - \bar{y})^2; MSQZ = SQZ / (i - 1)$$

$$SQE = \sum_{i=1}^I \sum_{j=1}^{J_i} (y_{ij} - \bar{y}_{i.})^2; MSQE = SQE / (n - i)$$

Beispieldatensatz

Koagulationsdatensatz von

<https://cran.r-project.org/doc/contrib/Faraway-PRA.pdf>

```
> if (!require(faraway)) {  
+   install.packages("faraway");require(faraway)}  
> data("coagulation")  
> head(coagulation, n=5)
```

	coag	diet
1	62	A
2	60	A
3	63	A
4	59	A
5	63	B

Beispieldatensatz II

```
> summary(coagulation)
```

	coag	diet
Min.	:56.00	A:4
1st Qu.:	61.75	B:6
Median	:63.50	C:6
Mean	:64.00	D:8
3rd Qu.:	67.00	
Max.	:71.00	

Beispieldatensatz Anova

```
> lmCoDi <- lm(coag ~ diet, data = coagulation)
> anova(lmCoDi)
```

Analysis of Variance Table

Response: coag

	Df	Sum Sq	Mean Sq	F value	Pr(>F)
diet	3	228	76.0	13.571	4.658e-05 ***
Residuals	20	112	5.6		

Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Maximum Likelihood

- Definition der Likelihood als gemeinsame Dichteverteilung der Daten (\mathbf{y}) gegeben die Parameter (\mathbf{b} , σ^2)

$$Pr(\mathbf{y}|\mathbf{b}, \sigma^2)$$

- Unter der Annahme einer Normalverteilung und nach Beobachtung der Daten als Funktion der Parameter aufgefasst, folgt

$$L(\mathbf{b}, \sigma^2; \mathbf{y}) = Pr(\mathbf{y}|\mathbf{b}, \sigma^2) = (2\pi\sigma^2)^{-\frac{n}{2}} \prod_{i=1}^n \exp\left[-\frac{(y_i - \mathbf{x}_i^T \mathbf{b})^2}{2\sigma^2}\right]$$

Maximierung der Likelihood Funktion

- Maximierung der Likelihood Funktion $L(\mathbf{b}, \sigma^2; \mathbf{y})$ ist analog zur Maximierung von

$$\begin{aligned}l(\mathbf{b}, \sigma^2; \mathbf{y}) &= \log(L(\mathbf{b}, \sigma^2; \mathbf{y})) \\ &= -\frac{n}{2} \log(2\pi\sigma^2) - \frac{1}{2\sigma^2} \sum_{i=1}^n (y_i - \mathbf{x}_i^T \mathbf{b})^2\end{aligned}$$

- Schätzungen für \mathbf{b} und σ erhalten wir durch Nullsetzen der partiellen Ableitungen von $l(\mathbf{b}, \sigma^2; \mathbf{y})$ nach \mathbf{b} und σ

Partielle Ableitung nach \mathbf{b}

- Partielle Ableitung von $l(\mathbf{b}, \sigma^2; \mathbf{y})$ nach \mathbf{b}

$$\frac{\partial l}{\partial \mathbf{b}} = -\frac{1}{2\sigma^2} \sum_{i=1}^n 2\mathbf{x}_i (y_i - \mathbf{x}_i^T \mathbf{b})$$

- Extremum ist erreicht, falls partielle Ableitung = 0, somit ist

$$\sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i^T \hat{\mathbf{b}} = \sum_{i=1}^n \mathbf{x}_i y_i$$

$$\hat{\mathbf{b}}_{ML} = \left(\sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i^T \right)^{-1} \sum_{i=1}^n \mathbf{x}_i y_i$$

- Beobachtung: $\hat{\mathbf{b}}_{LS} = \hat{\mathbf{b}}_{ML}$

Schätzer für σ^2

- Analoges Vorgehen, wie für \mathbf{b}
- Partielle Ableitung von $l(\mathbf{b}, \sigma^2; \mathbf{y})$ nach σ^2 null setzen
- Für \mathbf{b} setzen wir $\hat{\mathbf{b}}_{ML}$ ein

$$\frac{\partial l}{\partial \sigma^2} = -\frac{n}{2\sigma^2} + \frac{1}{2\sigma^4} \sum_{i=1}^n (y_i - \mathbf{x}_i^T \mathbf{b})^2$$

$$n\hat{\sigma}_{ML}^2 = \sum_{i=1}^n (y_i - \mathbf{x}_i^T \hat{\mathbf{b}}_{ML})^2$$

$$\hat{\sigma}_{ML}^2 = \frac{1}{n} \sum_{i=1}^n (y_i - \mathbf{x}_i^T \hat{\mathbf{b}}_{ML})^2$$

- $\hat{\sigma}_{ML}^2$ ist nicht erwartungstreu, d.h. $E[\hat{\sigma}_{ML}^2] \neq \sigma^2$

REML

- Restricted oder Residual Maximum Likelihood
- Basiert auf der Log-likelihood Funktion

$$l_{REML}(\sigma^2; \mathbf{y}) = -\frac{n-p}{2} \log(\sigma^2) - \frac{1}{2\sigma^2} \sum_{i=1}^n r_i^2$$

wobei:

$$r_i = y_i - \mathbf{x}_i^T \left(\sum_{i=1}^n \mathbf{x}_i \mathbf{x}_i^T \right)^{-1} \sum_{i=1}^n \mathbf{x}_i y_i$$

- l_{REML} ist unabhängig von \mathbf{b}
- Maximierung von l_{REML} führt zum Schätzer

$$\hat{\sigma}_{REML}^2 = \frac{1}{n-p} \sum_{i=1}^n r_i^2$$

Bayes'sche Methoden

Philosophie

- Welt der Statistik unterteilt sich in zwei Lager
 - 1 Frequentisten
 - 2 Bayesianer

Frequentisten

- Parameterschätzungen basieren auf ML oder REML
- Trennung zwischen Daten und Parameter, fehlende Daten werden ignoriert
- Effekte in Modellen werden in fix und zufällig unterteilt
- Keine Berücksichtigung von a priori Information

Bayes'sche Methoden II

Bayesianer

- Unterteilung in bekannte und unbekannte Größen, dies können Daten oder Parameter sein
- Schätzung von unbekanntem Größen basieren auf der a posteriori Verteilung der unbekanntem Größen gegeben die bekannten Größen
- Fehlende Daten können berücksichtigt werden
- A priori Information wird berücksichtigt

Beispiel für Bayes'sche Parameterschätzung

- Modell: $\mathbf{y} = \mathbf{X}\mathbf{b} + \mathbf{e}$
- Bekannte Größen sind die beobachteten Daten \mathbf{y}
- Unbekannte Größen sind die Parameter \mathbf{b} und σ
- Schätzungen für Unbekannte \mathbf{b} und σ werden gemacht aufgrund der a posteriori Dichteverteilungen $f(\mathbf{b}|\mathbf{y}, \sigma^2)$ und $f(\sigma^2|\mathbf{y}, \mathbf{b})$
- A posteriori Dichteverteilungen werden aufgrund des Satzes von Bayes berechnet

Satz von Bayes

$$f(\mathbf{b}|\mathbf{y}, \sigma^2) = \frac{f(\mathbf{y}|\mathbf{b}, \sigma^2)f(\mathbf{b})f(\sigma^2)}{f(\mathbf{y}, \sigma^2)}$$

wobei

$f(\mathbf{y} \mathbf{b}, \sigma^2)$	Bayes'sche Likelihood
$f(\mathbf{b})$	a priori Dichteverteilung von \mathbf{b}
$f(\sigma^2)$	a priori Dichteverteilung von σ^2
$f(\mathbf{y}, \sigma^2)$	Normalisierungskonstante

Bayes'sche Schätzung für \mathbf{b}

- Für Schätzung werden nur die von \mathbf{b} abhängigen Teile aus $f(\mathbf{b}|\mathbf{y}, \sigma^2)$ verwendet
- Konstante $f(\sigma^2)$ und $f(\mathbf{y}, \sigma^2)$ werden ignoriert
- Daraus folgt

$$f(\mathbf{b}|\mathbf{y}, \sigma^2) \propto f(\mathbf{y}|\mathbf{b}, \sigma^2)f(\mathbf{b})$$

- Ist a priori nichts über \mathbf{b} bekannt, dann wird $f(\mathbf{b})$ als konstant angenommen (uninformativer Prior)
- Weitere Vereinfachung zu

$$f(\mathbf{b}|\mathbf{y}, \sigma^2) \propto f(\mathbf{y}|\mathbf{b}, \sigma^2)$$

Bayes'sche Schätzung für \mathbf{b} II

- Unter der Annahme der Normalverteilung folgt

$$f(\mathbf{y}|\mathbf{b}, \sigma^2) = (2\pi\sigma^2)^{-\frac{n}{2}} \exp \left\{ -\frac{(\mathbf{y} - \mathbf{Xb})^T (\mathbf{y} - \mathbf{Xb})}{2\sigma^2} \right\}$$

- Damit die Dimensionen konsistent sind, machen wir folgende Transformation

$$\begin{aligned} f(\mathbf{b}|\mathbf{y}, \sigma^2) &\propto \exp \left\{ -\frac{(\mathbf{y} - \mathbf{Xb})^T (\mathbf{y} - \mathbf{Xb})}{2\sigma^2} \right\} \\ &\propto \exp \left\{ -\frac{(\mathbf{b} - \hat{\mathbf{b}})^T (\mathbf{X}^T \mathbf{X})(\mathbf{b} - \hat{\mathbf{b}})}{2\sigma^2} \right\} \end{aligned}$$

wobei: $\hat{\mathbf{b}} = (\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T \mathbf{y}$

Bayes'sche Schätzung III

- Schätzung für σ^2 analog basierend auf $f(\sigma^2|\mathbf{y}, \mathbf{b})$
- Schätzwerte basieren auf Momenten (Erwartungswert und Varianz) der a posteriori Dichteverteilungen
- Entsprechen die a posteriori Dichteverteilungen keinen Standarddichteverteilungen (wie Normal, Student-t, Beta, Gamma, ...), dann werden Erwartungswert und Varianzen aufgrund von Zufallszahlen von diesen Dichten approximiert
- Zufallszahlen werden aufgrund von Markovketten generiert