

Start:Bayes!

Gauss-Modelle

Sebastian Sauer



Gauss-Modelle

Ein Bayes-Modell für eine metrische Zielvariable ohne Prädiktoren.



Lernziele

Nach diesem Kapitel können Sie ...

- ein Gauss-Modell spezifizieren und mit `stan_glm()` in R berechnen
- an Beispielen zeigen, wie sich eine vage bzw. informationsreiche Priori-Verteilung auf die Posteriori-Verteilung auswirkt

Orientiert an McElreath ([2020](#)), Kap. 4.1–4.3.



**Wie groß sind die !Kung
San?**




Die Forschungsfrage

- Volk der !Kung San (Kalahari-Wüste, südliches Afrika)
- Frage: Wie groß sind die erwachsenen !Kung **im Durchschnitt?**
- Datensatz [Howell1a.csv](#), gefiltert auf Erwachsene (Alter ≥ 18)

Gesucht: der Populationsmittelwert der Körpergröße, μ .



Die Daten



Größe und Gewicht: recht symmetrisch/normalverteilt. Alter: rechtsschief.

Wie groß sind die !Kung San?



Unser Gauss-Modell der !Kung



Zwei Modellparameter


1. **Mittelwert** der Körpergröße in der Population, $\mu \rightarrow$ “Wie groß sind die erwachsenen !Kung im Durchschnitt?”
2. **Streuung** der Körpergrößen um den Mittelwert, $\sigma \rightarrow$ “Wie unterschiedlich groß sind die erwachsenen !Kung?”

Definition

Ein Gauss-Modell nimmt an, dass die Zielvariable normalverteilt ist mit Mittelwert μ und Streuung σ — beide selbst mit Priori-Verteilungen versehen.



Apriori mal Likelihood ist Post



The diagram shows three bell-shaped curves representing probability distributions. The first curve on the left is labeled 'Apriori'. To its right is a multiplication symbol '×'. The second curve is labeled 'Likelihood'. To its right is an equals sign '='. The third curve on the right is labeled 'Aposteriori'. This visualizes the equation: Prior × Likelihood = Posterior.

Diesmal berechnet **Stan** die Bayesbox für uns — nicht mehr von Hand.

Priori für den Mittelwert, μ

$$\mu \sim \mathcal{N}(178, 20) \quad \text{Prior}$$

- Mittelwert 178 cm, Streuung 20 cm
- Warum 178? Kein besonderer Grund — dient dazu, den Effekt verschiedener Priori-Werte zu untersuchen
- In echten Studien: Priori-Wert inhaltlich begründen (oder schwach-informative Standardwerte nutzen)



Priori für die Streuung, σ

$$\sigma \sim \mathcal{E}(1/8) \quad \text{Prior}$$


- Exponentialverteilt, da σ notwendig positiv ist
- Median bei $\lambda = 1/8$: ca. 5 cm
- Daraus folgt: 95% $KI(\mu) : 178 \pm 40$, also 138–218 cm

Groß genug für Überraschungen, eng genug gegen unmögliche Werte.




Die Priori-Verteilungen im Bild

$\mu \sim \text{dnorm}(178, 20)$



$\sigma \sim \text{dexp}(0.1)$



Hinweis

Dieses Modell hat zwei Parameter, μ und σ .

Die Likelihood

$$h_i \sim \mathcal{N}(\mu, \sigma) \quad \text{Likelihood}$$

- Lies: “Die Körpergröße ist normalverteilt mit Mittelwert μ und Streuung σ ”
- Für jede plausible Kombination von μ und σ berechnet Stan die Likelihood



Das vollständige Modell

$$\mu \sim \mathcal{N}(M = 178, S = 20)$$

Prior

$$\sigma \sim \mathcal{E}(1/8)$$

Prior

$$h_i \sim \mathcal{N}(\mu, \sigma)$$

Likelihood

Das ist unser Modell `m_kung`.




Post-Verteilung mit Stan berechnen

```
1 m_kung <-  
2   stan_glm(height ~ 1,  
3     prior_intercept = normal(178, 20),  
4     prior_aux = exponential(1/8),  
5     refresh = 0,  
6     data = kung_erwachsen)
```


- `height ~ 1`: Regression **ohne** Prädiktor — nur die Verteilung der AV wird geschätzt
- `(Intercept)` entspricht dem Mittelwert μ



Die Randverteilungen von μ und σ



Die gemeinsame Post-Verteilung



Für jede Kombination von μ und σ : Wie wahrscheinlich ist sie? Hier: μ und σ sind unkorreliert.

Zusammenfassung: Modell **m_kung**

- Wir erhalten eine Wahrscheinlichkeitsverteilung für μ und für σ (bzw. eine gemeinsame Verteilung)
- Trotz vagem Prior: kleine Streuung der Post-Werte — große Stichprobe überstimmt den Prior
- Aus der Post-Verteilung können wir Stichproben ziehen und Fragen beantworten



Hallo, Posteriori- Verteilung



Fragen an die Posteriori-Verteilung

1. Mit welcher Wahrscheinlichkeit ist die *mittlere* !Kung-Person größer als 1,55 m?
2. Welche mittlere Körpergröße wird mit 95 % Wahrscheinlichkeit nicht überschritten?
3. In welchem 90 %-PI liegt μ vermutlich?
4. Wie unsicher ist die Schätzung der mittleren Körpergröße?
5. Was ist der mediane Schätzwert, der “Best Guess”?



Antworten: einfache Anteile berechnen

```
1 m_kung_post %>%  
2   count(mu > 155) %>%  
3   mutate(prop = n/sum(n))
```

- $P(\mu > 155)$: eher gering, aber nicht ausgeschlossen
- $P(\mu > 165)$: praktisch ausgeschlossen — aber **nur unter dem Modell!**

⚠ Kleine-Welt-Aussage

Diese Wahrscheinlichkeiten gelten nur, wenn das Modell (die Annahmen) zutrifft.

Parameterschätzung komfortabel

```
1 parameters(m_kung)
```

- Golem schätzt den Größenmittelwert auf ca. 155 cm
- 95 %-ETI (Equal-Tailed Interval, synonym zu PI) gibt den Unsicherheitsbereich an
- Zusatzangaben wie `pd`, `Rhat`, `ESS`: vorerst ignorieren



Wie tickt `stan_glm()`?

Kerninfos zu `stan_glm()`

- Stan: Software zur Berechnung von Bayes-Modellen;
`rstanarm` stellt sie in R bereit
- `stan_glm()` ist für Regressionsmodelle ausgelegt
- Verteilung einer einzelnen Variable schätzen = Regression
ohne Prädiktor: $y \sim 1$
- `(Intercept)` = Mittelwert



Ketten und Geschwindigkeit

- Stan zieht standardmäßig **4 Ketten** (chains) — zur gegenseitigen Kontrolle
- Stimmen alle Ketten überein → vertrauenswürdiges Ergebnis
- Weichen sie ab → Fehler oder Problem im Modell
- `chains = 1` spart Zeit, aber ohne Kontrolle



Standard-Prioriwerte von `stan_glm()`

Ohne eigene Angabe wählt Stan die Prioris selbst — basierend auf den Stichprobendaten.

Standardwerte von `stan_glm`

- `Intercept`: $\mu \sim \mathcal{N}(\bar{Y}, sd(Y) \cdot 2.5)$
- `Auxiliary (sigma)`: $\sigma \sim \mathcal{E}(\lambda = 1/sd(Y))$

Das ist strenggenommen nicht “pures Bayes” — die Prioris basieren teils auf den Daten selbst.

Modell

m_kung_neue_prioris:

Standard-Priori-Werte


Modell mit Standard-Prioris

- `m_kung` (eigene Prioris) vs. `m_kung_neue_prioris` (Standard-Prioris)
- Ergebnis: **sehr ähnliche** Parameterwerte

! Merksatz

Bei ausreichend großer Stichprobe fallen moderate Priori-Unterschiede kaum ins Gewicht.

Post-Verteilung des Intercepts




Posterior-Prädiktiv-Verteilung

- Bisher: Verteilung von μ (mittlere Körpergröße)
- Jetzt: Verteilung der **tatsächlichen** Körpergrößen h_i laut Modell
- Für jede Stichprobe (μ, σ) eine Normalverteilung ziehen $\rightarrow$ Posterior-Prädiktiv-Verteilung



Modellcheck: passt das Modell zu den Daten?



Dunkle Kurve: tatsächliche Daten. Helle Kurven: Simulationen aus der Post-Verteilung. Das Modell bildet die Realität gut ab.

Fazit

Was wir gelernt haben

- Posteriori-Verteilung für ein Gauss-Modell berechnet: metrische AV ohne Prädiktoren
- Zielvariable `height` ~ normalverteilt mit μ und σ
- Für μ und σ : keine fixen Werte, sondern Wahrscheinlichkeitsverteilungen (Prioris)

! Merksatz


Kontinuierliches Lernen ist der Schlüssel zum Erfolg.

Vertiefung: Wahl der Priori-Werte




Vertiefung: Priori-Prädiktiv-Verteilung

- Simuliert Beobachtungen **nur** auf Basis der Prioris (vor Kenntnis der Daten)
- $h_i \sim \mathcal{N}(\mu, \sigma)$, $\mu \sim \mathcal{N}(178, 20)$, $\sigma \sim \mathcal{E}(0.1)$
- Prüft, ob die Priori-Annahmen plausibel sind



Vage Prioris können in die Irre führen



- Mit $\sigma \sim \mathcal{E}(0.01)$ (extrem vage): Modell erwartet z. T. **negative** Körpergrößen und Riesen
- Vage (“objektive”, flache) Prioris sind oft **keine gute Wahl** — sie lassen unplausible Werte zu

! Merksatz

Ein Prior sollte weder übergewiss noch beliebig vage sein — Plausibilität zählt.

Vertiefung: Wahl der Priori-Werte



Zusammenfassung: Priori-Wahl

- Prioris transparent und begründet wählen
- Alternative: schwach-informative Standardwerte (z. B. `rstanarm`-Default)
- Prüfen lässt sich die Priori-Wahl mit der **Priori-Prädiktiv-Verteilung**
- Bei großer Stichprobe: Einfluss des Priors sinkt ohnehin



Vielen Dank!

Fragen?

McElreath, R. (2020). *Statistical Rethinking: A Bayesian Course with Examples in R and Stan* (2. Aufl.). Taylor and Francis, CRC Press.

