

# Modellierung ordinaler Präferenzen

mit `{RprobitB}` am Beispiel des pairfam Panels

Lennart Oelschläger   Dietmar Bauer

Universität Bielefeld, Fakultät für Wirtschaftswissenschaften, Lehrstuhl für Ökonometrie

10. November 2022

- 1 Ordered Probit Modell
- 2 Anwendung am pairfam Panel
- 3 Computerwerkstatt: {RprobitB}

- 1 Ordered Probit Modell
- 2 Anwendung am pairfam Panel
- 3 Computerwerkstatt: {RprobitB}

## Antwortskalen bei Umfragen

- Kardinalskala: Klassische lineare Regression
  - z.B. Modellierung des Einkommens
- Nominalskala: Wahlmodelle
  - z.B. Modellierung der Wahl eines Verhütungsmittels (Vortrag letztes Jahr)
- Ordinalskala: **Ordered Probit Modell**
  - z.B. Modellierung von Antworten auf einer Likert-Skala

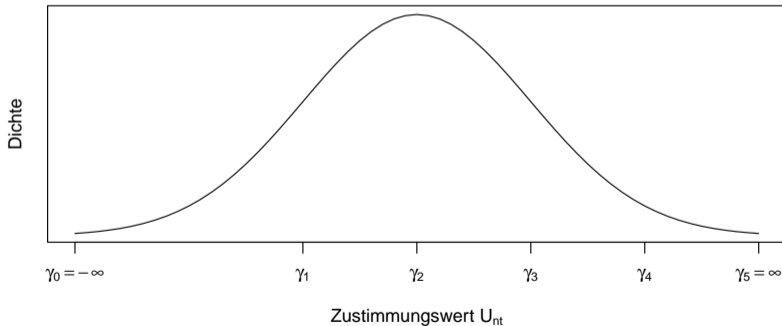
Gegeben eine Frage mit  $J$  geordneten Antwortmöglichkeiten.

Modelliere für Person  $n = 1, \dots, N$  bei der Wahlsituation  $t = 1, \dots, T(n)$ :

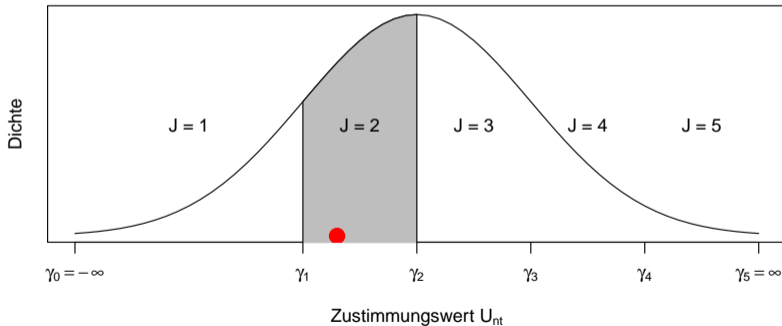
$$U_{nt} = X'_{nt}\beta + \epsilon_{nt}$$

- $U_{nt} \in \mathbb{R}$  ist der stetige Zustimmungswert von  $n$  bei  $t$
- $X_{nt} \in \mathbb{R}^P$  ist der Vektor mit  $P$  Charakteristiken von  $n$  bei  $t$
- $\beta \in \mathbb{R}^P$  ist der zu schätzende Koeffizientenvektor
- $\epsilon_{nt} \in \mathbb{R}$  ist der Fehlerterm für  $n$  bei  $t$  mit  $\epsilon_{nt} \sim N(\mu, \sigma)$  (Probit Modellklasse)

In diesem Beispiel:  $J = 5$  Antwortmöglichkeiten



In diesem Beispiel:  $J = 5$  Antwortmöglichkeiten



Es bezeichne  $y_{nt} \in \{1, \dots, J\}$  die Antwort von  $n$  bei  $t$ . Dann:

$$y_{nt} = \sum_j j \cdot 1\{\gamma_{j-1} < U_{nt} \leq \gamma_j\}$$

mit  $\gamma_0 = -\infty$  und  $\gamma_J = +\infty$ .

Das heißt, Antwortalternative  $j$  wird genau dann gewählt, wenn  $U_{nt} \in (\gamma_{j-1}, \gamma_j]$ .

Monotonie der Grenzen: Anstelle von  $\gamma_j$ ,  $j = 1, \dots, J - 1$ , schätze  $d_j$  mit

$$\gamma_j = \sum_{i \leq j} \exp(d_i).$$



Modellgleichung für  $n$  bei  $t$ :

$$U_{nt} = X'_{nt}\beta + \epsilon_{nt}$$

Die Zustimmungswerte  $U_{nt}$  sind invariant bezüglich

- Skala:  $U_{nt} \in (\gamma_{j-1}, \gamma_j] \Leftrightarrow c \cdot U_{nt} \in (c \cdot \gamma_{j-1}, c \cdot \gamma_j]$  für alle  $c \in \mathbb{R}_+$ 
  - Lösung: Fixiere zum Beispiel  $\sigma = 1$  oder  $\mu = 0$
- Level:  $U_{nt} \in (\gamma_{j-1}, \gamma_j] \Leftrightarrow c + U_{nt} \in (c + \gamma_{j-1}, c + \gamma_j]$  für alle  $c \in \mathbb{R}$ 
  - Lösung: Fixiere zum Beispiel  $\gamma_1 = 0$

Anstelle eines konstanten  $\beta$  für jeden Befragten  $n = 1, \dots, N$ :

$$\beta_n \sim f$$

Die Verteilung  $f$  ist eine Modellspezifikation, z.B.

- ein Produkt unabhängiger Marginalverteilungen (z.B. Normalverteilung, Log-Normal Verteilung)
- eine multivariate Verteilung (erlaubt Korrelation zwischen Effekten)
- eine Latente Mischung:

$$\beta_n \sim \sum_{c=1, \dots, C} s_c \cdot \text{MVN}(b_c, \Omega_c)$$

Grundlegende Formel:

$$\underbrace{\Pr(\text{Parameter} \mid \text{Daten})}_{\text{A-posteriori-Verteilung}} \propto \underbrace{\Pr(\text{Parameter})}_{\text{A-priori-Verteilung}} \cdot \underbrace{\Pr(\text{Daten} \mid \text{Parameter})}_{\text{Likelihood}}$$

Für das **Ordered Probit Modell**:

$$\Pr(\beta, \sigma, d \mid y) \propto \Pr(\beta, \sigma, d) \cdot \underbrace{\Pr(y \mid \beta, \sigma, d)}_{\text{Likelihood}}$$

Müssen Likelihood nicht berechnen (zeitintensiv), wenn  $(U_{nt})$  "augmentiert" wird:

$$\Pr(\beta, \sigma, d, U \mid y) \propto \Pr(\beta, \sigma, d) \cdot \Pr(U \mid \beta, \sigma, d) \cdot 1\{y_{nt} = j \Leftrightarrow U_{nt} \in (\gamma_{j-1}, \gamma_j]\}$$

## Methode: Gibbs Sampling

- Gesucht: Zufallszahlen von  $f(X, Y)$
- Bekannt:  $f(X|Y)$  und  $f(Y|X)$
- Algorithmus:
  - Initialisiere  $X^0$  und  $Y^0$
  - Für  $r = 1, \dots, R$ :  $X^j \sim f(X|Y^{j-1})$   
und  $Y^j \sim f(Y|X^j)$
- Dann:  $(X^r, Y^r) \sim f(X, Y)$  für  
 $r = Q + 1, \dots, R$  ("Burn-in" Phase)

## A-posteriori-Verteilung der Modellparameter durch Gibbs Sampling approximieren:

- $U \sim$  Trunkierte Normalverteilung
- $\sigma \sim$  Inverse Wishart-Verteilung (bei konjugierter Prior)
- $\beta \sim$  Multivariate Normalverteilung (bei konjugierter Prior)
- $d$  mittels Metropolis-Hastings (keine direkte Ziehung aus der Marginalverteilung möglich)

- 1 Ordered Probit Modell
- 2 Anwendung am pairfam Panel
- 3 Computerwerkstatt: {RprobitB}

## Deutsches Beziehungs- und Familienpanel

- Circa 12.000 “Anchors” (Hauptbefragte)
- Auch Befragung von Eltern, Kindern, Partnern
- Durchschnittlich circa 150 Variablen pro Befragung
- In diesem Vortrag:
  - Release 11.0 (11 Erhebungswellen von 2008/09 bis 2018/19)
  - “NA Fälle” ignoriert (MCAR Annahme)



## Frage 3

Variable  
val1\_

Zunächst geht es um allgemeine Ansichten zu Familie und Familienleben.  
Bitte sagen Sie mir, wie sehr Sie persönlich diesen Ansichten zustimmen.

Int.: Liste 1 vorlegen!

- val1i1 Eltern und Kinder sollten sich ein Leben lang gegenseitig unterstützen
- val1i2 Man sollte heiraten, wenn man mit einem Partner auf Dauer zusammenlebt.
- val1i3 Frauen sollten sich stärker um die Familie kümmern als um ihre Karriere.
- val1i4 Männer sollten sich genau so an der Hausarbeit beteiligen wie Frauen.
- val1i5 Ein Kind unter 6 Jahren wird darunter leiden, wenn seine Mutter arbeitet.
- val1i6 Kinder leiden oft darunter, dass sich ihre Väter zu sehr auf die Arbeit konzentrieren.
- val1i7 Die Ehe ist eine lebenslange Verbindung und sollte nicht beendet werden.
- val1i8 Man sollte spätestens dann heiraten, wenn ein Kind da ist.

Stimme überhaupt nicht zu	1	2	3	4	5	Stimme voll zu
	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	
	<i>Weiß nicht</i> .....				<input type="checkbox"/> -1	
	<i>Keine Angabe</i> .....				<input type="checkbox"/> -2	

# Fragen mit diskreter, ordinaler Antwortskala



## Frage 3

Variable  
val1\_

Zunächst geht es um allgemeine Ansichten zu Familie und Familienleben.  
Bitte sagen Sie mir, wie sehr Sie persönlich diesen Ansichten zustimmen.

Int.: Liste 1 vorlegen!

- val1i1 Eltern und Kinder sollten sich ein Leben lang gegenseitig unterstützen
- val1i2 Man sollte heiraten, wenn man mit einem Partner auf Dauer zusammenlebt.
- val1i3 Frauen sollten sich stärker um die Familie kümmern als um ihre Karriere.
- val1i4 Männer sollten sich genau so an der Hausarbeit beteiligen wie Frauen.
- val1i5 Ein Kind unter 6 Jahren wird darunter leiden, wenn seine Mutter arbeitet.
- val1i6 Kinder leiden oft darunter, dass sich ihre Väter zu sehr auf die Arbeit konzentrieren.
- val1i7 Die Ehe ist eine lebenslange Verbindung und sollte nicht beendet werden.**
- val1i8 Man sollte spätestens dann heiraten, wenn ein Kind da ist.

Stimme überhaupt nicht zu

1	2	3	4	5
<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>	<input type="checkbox"/>

Stimme voll zu

Weiß nicht ..... -1






Keine Angabe ..... -2



```
summary(data)
```

```
## count
## deciders 11135
## choice occasions 1-6
## total choices 27207
## alternatives 5
## - '1' 4186
## - '2' 4025
## - '3' 6466
## - '4' 5649
## - '5' 6881
```


```
plot(data, by_choice = TRUE)
```



```
formula <- marriage ~ 1 + age + gender + rel_stat + income
```

## Average effects

The horizontal lines show  $\pm 3$  standard deviation of the estimate



Geschätzte Modellparameter  $\gamma$ :

```
## gamma_0 gamma_1 gamma_2 gamma_3 gamma_4 gamma_5  
##      -Inf      0.00      0.94      1.71      2.39      Inf
```


Beispiel:

- $\hat{\beta}_{\text{rel\_stat}} = 0.77$
- eine Person würde mit Eintritt in eine Beziehung immer von Antwortkategorie 4 zu 5 wechseln (ceteris paribus)
- aber nicht zwangsläufig von 2 zu 3 (ceteris paribus)

```
formula <- marriage ~ 1 + age + gender + rel_stat + income  
re <- c("age", "rel_stat", "income")  
C <- 3
```

## Average effects

The horizontal lines show  $\pm 1$  standard deviation of the estimate



```
classes <- classification(mod)
```

```
head(classes, n = 3)
```

```
##           1         2         3 est
## 111000 0.3720 0.3892 0.2388  2
## 174000 0.5504 0.4432 0.0064  1
## 423000 0.4168 0.5328 0.0504  2
```

```
get_cov(mod, id = "111000")
```

```
##      id      wave      age gender rel_stat      income marriage
## 7 111000 2014/15 1.303499      1         0 -0.7610623         1
```

- 1 Ordered Probit Modell
- 2 Anwendung am pairfam Panel
- 3 Computerwerkstatt: {RprobitB}**

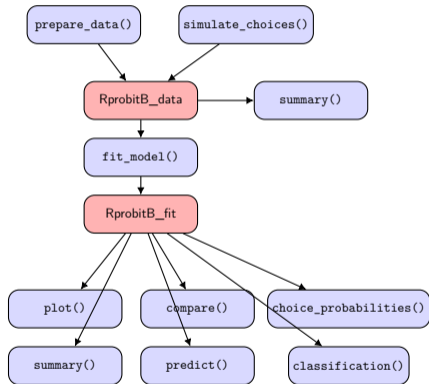


Bayesianische Schätzung von Probit Wahlmodellen

 [CRAN.R-project.org/package=RprobitB](https://CRAN.R-project.org/package=RprobitB)

 [loeschlaeger.de/RprobitB](https://loeschlaeger.de/RprobitB)

 [github.com/loeschlaeger/RprobitB](https://github.com/loeschlaeger/RprobitB)



Paket installieren und laden:

```
install.packages("RprobitB")  
packageVersion("RprobitB") # sollte >= 1.1.2 sein  
library("RprobitB")
```

File mit R Code herunterladen und in R öffnen:

 [loeschlaeger.de/files/code/aka22\\_rprobitb.R](https://loeschlaeger.de/files/code/aka22_rprobitb.R)



# Danke für die Aufmerksamkeit!

## Zusammengefasst:

- Modellierung von ordinalskalierten Antworten
- Klassifizierung von Befragten mittels latenter Klassen
- Modell Selektion wurde nicht behandelt

## Ich freue mich über:

- Fragen und Anregungen zum Modell und zum R Paket
- Methodenvergleiche
- Datensätze über ordinale Wahlsituationen



[loeschlaeger.de/talks](https://loeschlaeger.de/talks)



[loeschlaeger@uni-bielefeld.de](mailto:loeschlaeger@uni-bielefeld.de)