

Geoadditive Hazard Regression bei intervallzensierten Überlebenszeiten


Thomas Kneib
Teilprojekte **A5**, **B2**, **C1**

1. Kindersterblichkeit in Nigeria
2. Intervallzensierte Überlebenszeiten
3. Strukturierte Hazard Regression
4. Inferenz basierend auf gemischten Modellen
5. Software
6. Kindersterblichkeit in Nigeria II
7. Simulationsergebnisse

Kindersterblichkeit in Nigeria

- Daten aus dem 2003 Demographic and Health Survey (DHS) in Nigeria.
- **Retrospektive Befragung** zum Gesundheitszustand von Frauen im gebärfähigen Alter und deren Kindern.
- Überlebenszeiten zu $n = 5323$ Kindern.
- Zahlreiche Kovariablen inklusive **räumlicher Information**.
- Analyse basierend auf dem **Cox-Modell**:


$$\lambda(t; u) = \lambda_0(t) \exp(u' \gamma).$$



- **Einschränkungen** des klassischen Cox-Modells:
 - Beschränkt auf rechtszensierte Beobachtungen.
 - Nachträgliche Schätzung der Baseline Hazardrate.
 - Annahme proportionaler Hazardraten.
 - Parametrische Form des Prädiktors.
 - Keine räumlichen Korrelationen.
- Erweiterungen in Bezug auf einzelne Probleme existieren, aber es fehlt eine **Kombination aller Probleme**.


Intervallzensierte Überlebenszeiten

- Theoretisch wird die Überlebenszeit in Tagen erhoben.
- Retrospektives Design \Rightarrow die meisten unzensierten Überlebenszeiten sind gerundet.



- Zensierte Überlebenszeiten sind dagegen exakt erhältlich.

\Rightarrow Betrachte Überlebenszeiten als **intervallzensiert**.



- Likelihood-Beiträge:

$$P(T \in [T_{lower}, T_{upper}]) = S(T_{lower}) - S(T_{upper})$$

- Können in Abhängigkeit der Hazardrate geschrieben werden:

$$S(t) = \exp\left(-\int_0^t \lambda(u) du\right).$$

- Ableitungen der Log-Likelihood werden wesentlich komplizierter.
- **Numerische Integrationsverfahren** müssen verwendet werden.
- Stückweise konstante, **zeitvariierende Kovariablen** und **Linkstrunkierung** können einfach berücksichtigt werden.

Strukturierte Hazard Regression

- Flexibles, **semiparametrisches Modell** für die Hazardrate:

$$\lambda(t; \cdot) = \exp \left[g_0(t) + \sum_{j=1}^q g_j(t) z_j + \sum_{k=1}^p f_k(x_k) + f_{spat}(s) + u(t)' \gamma \right]$$

wobei

$g_0(t) = \log(\lambda_0(t))$ **logarithmierte Baseline-Hazardrate,**

g_j **zeitvariierende Effekte** der Kovariablen z_j ,

f_k **nonparametrische Funktionen** der stetigen Kovariablen x_k ,

f_{spat} **räumliche Funktion,**

$u(t)$ **zeitvariierende Kovariablen.**

- **P-Splines:**
 - Approximiere $f_k(x_k)$ bzw. $g_j(t)$ durch große Zahl von B-Spline-Basisfunktionen.
 - Bestrafe Differenzen benachbarter Regressionskoeffizienten.
- **Markov Zufallsfelder:**
 - Geeignet für Regionendaten.
 - Definiere Nachbarschaften für die Regionen.
 - Erwartungswert von $f_{spat}(s)$ ist der Mittelwert der Funktionsauswertungen benachbarter Regionen.
- **Stationäre Gaussfelder (Kriging):**
 - Geeignet für exakte Lokationen.
 - Der räumliche Effekt folgt einem stationären stochastischen Prozess.
 - Die Korrelation zweier Punkte wird durch eine intrinsische Korrelationsfunktion beschrieben.

- **Erweiterungen:**
 - Interaktionsoberflächen (2D P-splines).
 - Variierende Koeffizienten (stetige und räumliche Effektmodifizierer).
 - Frailties (i.i.d. random effects).
- Alle Effekte können in einem **einheitlichen Rahmen** geschätzt werden.

Inferenz basierend auf gemischten Modellen

- Jeder Term im Prädiktor wird beschrieben durch einen Vektor von Regressionskoeffizienten mit **uneigentlicher multivariater Normalverteilungs-Priori**:

$$p(\beta_j | \tau_j^2) \propto \exp \left(-\frac{1}{2\tau_j^2} \beta_j' K_j \beta_j \right)$$


- K_j ist eine **Strafmatrix**, τ_j^2 ein **Glättungsparameter**.

⇒ Reparametrisierung des Modells in ein **gemischtes Modell mit normierbaren Verteilungen**.

- Empirische Bayes-Schätzer erhält man durch Iteration der folgenden Schritte:
 - Penalisierte Maximum Likelihood-Schätzung der Regressionskoeffizienten.
 - Restricted Maximum Likelihood- / Marginale Likelihood-Schätzung der Varianzparameter.

Software

- Implementiert im Softwarepaket BayesX.
- BayesX erlaubt
 - beliebige Kombinationen von Links-, Rechts-, und Intervallzensierung sowie Linkstrunkierung,
 - die gleichzeitige Schätzung der Baseline-Hazardrate und der Kovariableneffekte,
 - den Einbezug zeitvariierender Effekte und zeitvariierender Kovariablen,
 - nonparametrische Effekte, räumliche Effekte, Interaktionsoberflächen und Frailties.
- Erhältlich unter




<http://www.stat.uni-muenchen.de/~bayesx>

Kindersterblichkeit in Nigeria II


- Modell:

$$\lambda(t) = \exp(\eta(t))$$


$$\begin{aligned}\eta(t) = & g_0(t) \\ & + f_{spat}(distrikt) \\ & + f_1(bmi) + f_2(alter) + f_3(geburtsordnung) + f_4(haushaltsgroesse) \\ & + \beta_1 stillen(t) \\ & + \beta_2 geschlecht + \dots\end{aligned}$$



Alter der Mutter bei der Geburt.




Räumlicher Effekt.



Body Mass Index der Mutter.

Kovariable	Schätzer	p-Wert
Intercept	-8.27	<0.0001
Stillen (zeitvariierend)	-4.27	<0.0001
Geburt im Krankenhaus	-0.54	0.0001
Lange Geburt	0.28	0.0047
Christen	-0.52	0.0001
Moslems	0.79	
Andere	-0.27	0.2879



Simulationsergebnisse

- Vergleich von
 - Intervallzensierung,
 - Zeitdiskreten Modellen,
 - Zufälliger Verteilung der Beobachtungen über die Intervalle.
- Design:
 - $\lambda(t) = \lambda_0(t) \exp [f_1(x) + f_{spat}(s)]$.
 - Intervallzensierte und rechtszensierte Beobachtungen.
 - Rauhe und glatte Baseline-Hazardraten.

- Ergebnisse für die **Baseline-Hazardrate**:
 - Bei rauher Baseline-Hazardrate bessere Schätzung durch den Intervallzensierungsansatz.
 - Bei glatter Baseline können andere Verfahren besser abschneiden.
- Ergebnisse für die **Kovariableneffekte**:
 - Bei kleiner Anzahl breiter Intervalle liefert der Intervallzensierungsansatz die besten Ergebnisse.
 - Bei vielen schmalen Intervallen fast keine Unterschiede mehr.

Diskussion

- Bayesianisches Modell zur Analyse komplexer Hazard Regressionsmodelle bei intervallzensierten Daten **ohne Verwendung von MCMC Simulationstechniken**.
⇒ Keine Fragen zu Konvergenz und Mixing.
- Eng verwandt mit **penalisierter Likelihood** Schätzung in einem frequentistischen Kontext.
- **Erweiterungen:**
 - Mehrzustands-Modelle.
 - Konkurrierende Risiken.
 - Einbezug von Intervallzensierung in diese komplexeren Modellen.

Referenzen

- Kneib, T. and Fahrmeir, L. (2004): A mixed model approach for structured hazard regression. SFB 386 Discussion Paper 400, University of Munich.
- Kneib, T. (2005): Geoadditive hazard regression for interval censored survival times. SFB 386 Discussion Paper 447, University of Munich.
- Erhältlich unter

<http://www.stat.uni-muenchen.de/~kneib>