

Bayesian Model Averaging im Survival Kontext

Alexander Volkmann

20. Juni 2017

Seminar Moderne statistische Methoden in der Epidemiologie
Ludwig-Maximilians-Universität München



- 1 Motivation
- 2 Einführung in die Bayesianische Statistik
- 3 Theorie des Bayesian Model Averaging
- 4 Implementierung im Survival-Kontext
- 5 Anwendungsbeispiel
- 6 Zusammenfassung und Ausblick

- 1 Motivation
- 2 Einführung in die Bayesianische Statistik
- 3 Theorie des Bayesian Model Averaging
- 4 Implementierung im Survival-Kontext
- 5 Anwendungsbeispiel
- 6 Zusammenfassung und Ausblick

Datengrundlage

Eine von 1974 bis 1984 durchgeführte randomisierte klinische Studie an 312 Patienten mit Primärer Biliärer Zirrhose

Ziel

Modell für Verlauf der Krankheit erstellen

(Welche Variablen haben Einfluss auf das Versterben der Patienten?

Prognose für einzelne Patienten?)

Datengrundlage

Eine von 1974 bis 1984 durchgeführte randomisierte klinische Studie an 312 Patienten mit Primärer Biliärer Zirrhose

Ziel

Modell für Verlauf der Krankheit erstellen

(Welche Variablen haben Einfluss auf das Versterben der Patienten?

Prognose für einzelne Patienten?)

pbc-Datensatz

- Anzahl der Tage zwischen Registrierung und dem Eintreten der Transplantation, des Todes oder des Studienendes
- Status am Enpunkt (zensiert, transplantiert oder tot)
- 15 mögliche Risikofaktoren (Kovariablen)

Variable	Variablenbeschreibung	Mittelwert
age	Alter in Jahre	50,02
albumin	Albumin im Serum (g/dl) [logarithmiert]	1,25
bili	Bilirubin im Serum (mg/dl) [logarithmiert]	0,58
edema	Ödem (0: nicht vorhanden; 0,5: unbehandelt oder erfolgreich behandelt; 1: Ödem trotz Therapie)	0,11
protime	Standardisierte Blutgerinnungszeit [logarithmiert]	2,37
stage	Histologisches Krankheitsstadium, Biopsie benötigt (1-4)	3,03
copper	Kupfer im Urin (ug/Tag) [logarithmiert]	4,26
⋮	⋮	⋮

Lebensdauer-Modelle

Cox Proportional Hazards Modell

$$\lambda(t | X_i) = \lambda_0(t) \exp(X_i \beta)$$

- t Zeitpunkt
- X_i Vektor der Kovariablenausprägungen für Patient i
- β Vektor der unbekannt Parameter
- λ Hazard-Rate
- λ_0 Baseline-Hazard (unspezifiziert)

Backwards-Elimination

Beliebte Variablenselektionsmethode:

- 1 Beginne mit vollem Modell
- 2 Berechne p-Werte der einzelnen Koeffizienten
- 3 Entferne die Variable aus dem Modell, deren p-Wert am größten ist
- 4 Passe Modell neu an
- 5 Wiederhole Schritte 2 bis 4 bis alle p-Werte $< 0,05$

Ergebnis des BE-Modells

	coef	exp(coef)	se(coef)	z	p
age	0.03	1.03	0.01	3.66	0.00
albumin	-2.83	0.06	0.74	-3.82	0.00
bili	0.76	2.14	0.11	6.63	0.00
edema	0.82	2.27	0.30	2.72	0.01
protime	3.06	21.39	1.10	2.78	0.01
copper	0.36	1.43	0.14	2.63	0.01

Dieses Vorgehen ist problematisch!

- ① Durch das wiederholte Testen verlieren die p-Werte ihre gewohnte Bedeutung
- ⇒ Signifikanzniveau für Inferenz nicht mehr bekannt

Dieses Vorgehen ist problematisch!

- ① Durch das wiederholte Testen verlieren die p-Werte ihre gewohnte Bedeutung
- ⇒ Signifikanzniveau für Inferenz nicht mehr bekannt

Lösungsansätze

- **Post-Selection Inference:**
Z.B. Modellbildung und Inferenz auf unabhängigen Datensätzen durchführen

- ② Durch das Ausschließen von Variablen basierend auf statistische Tests wird auch das End-Modell „zufällig“
 - ⇒ Auch ein anderes Modell hätte ausgewählt werden können
 - ⇒ **Unsicherheit wird unterschätzt**

- ② Durch das Ausschließen von Variablen basierend auf statistische Tests wird auch das End-Modell „zufällig“
 - ⇒ Auch ein anderes Modell hätte ausgewählt werden können
 - ⇒ **Unsicherheit wird unterschätzt**

Lösungsansätze

- **Bayesian Model Averaging:**
Methode, um die Modellunsicherheit zu berücksichtigen
 - ⇒ Mittellung der Ergebnisse über mehrere Modelle

- 1 Motivation
- 2 Einführung in die Bayesianische Statistik**
- 3 Theorie des Bayesian Model Averaging
- 4 Implementierung im Survival-Kontext
- 5 Anwendungsbeispiel
- 6 Zusammenfassung und Ausblick

Abgrenzung zur klassischen Statistik

Parametervektor θ eines Wahrscheinlichkeitsmodells ist in der Bayesianischen Statistik zufällig und besitzt eine Verteilung

Abgrenzung zur klassischen Statistik

Parametervektor θ eines Wahrscheinlichkeitsmodells ist in der Bayesianischen Statistik zufällig und besitzt eine Verteilung

Anwendung des Satz von Bayes

$$f(\theta | x) = \frac{f(\theta, x)}{f(x)} = \frac{f(x | \theta)f(\theta)}{\int f(x | \theta)f(\theta)d\theta}$$

θ	Parametervektor
x	Realisierung der zufälligen Daten X
$f(\theta)$	Priori-Verteilung von θ
$f(x \theta)$	Likelihood der Daten x
$f(\theta x)$	Posteriori-Verteilung von θ

Posteriori-Verteilung als Grundlage der Inferenz

Punktschätzer über Posteriori-Erwartungswert, -Median oder -Modus

Modellwahl

Über Marginale Likelihood

$$f(x | M_i) = \int f(x | \theta_i, M_i) f(\theta_i | M_i) d\theta_i$$

Posteriori-Verteilung als Grundlage der Inferenz

Punktschätzer über Posteriori-Erwartungswert, -Median oder -Modus

Modellwahl

Über Marginale Likelihood

$$f(x | M_i) = \int f(x | \theta_i, M_i) f(\theta_i | M_i) d\theta_i$$

oder Bayes'sches Informationskriterium

$$BIC = 2 \log f(x | \hat{\theta}_{ML}, M_i) - p \log(n) \doteq 2 \log f(x | M_i)$$

mit Modell M_i , Maximum-Likelihood Schätzer $\hat{\theta}_{ML,p}$ der Anzahl der Dimensionen von θ und n der Größe des Stichprobenumfangs

- 1 Motivation
- 2 Einführung in die Bayesianische Statistik
- 3 Theorie des Bayesian Model Averaging**
- 4 Implementierung im Survival-Kontext
- 5 Anwendungsbeispiel
- 6 Zusammenfassung und Ausblick

Berücksichtigung der Modelunsicherheit

Mehrere Modelle M_1, \dots, M_K werden an die Daten D angepasst

Mittelung über Modelle

Gewichtetes Mittel über die Modelle, um Aussagen über die interessierende Größe Δ zu treffen

⇒ Posteriori-Modellwahrscheinlichkeit als Gewichte

Um die Wahrscheinlichkeit des Modells M_k gegeben die Daten D zu berechnen, kann wieder der Satz von Bayes verwendet werden:

$$P(M_k | D) = \frac{P(D | M_k)P(M_k)}{\sum_{l=1}^K P(D | M_l)P(M_l)},$$

wobei $P(D | M_k)$ bereits als marginale Likelihood bekannt ist:

$$P(D | M_k) = \int P(D | \theta_k, M_k)P(\theta_k | M_k)d\theta_k$$

und $P(M_k)$ die Priori-Modellwahrscheinlichkeit bezeichnet.

Verteilung von Δ in einem Modell

Um Aussagen über die interessierende Größe Δ zu treffen, wird in der Bayesianischen Statistik die Prädiktive (Posteriori-) Verteilung betrachtet:

$$P(\Delta | M_k, D) = \int P(\Delta | \theta_k, M_k, D)P(\theta_k | M_k, D)d\theta_k.$$

Berücksichtigung aller Modelle

Gewichtetes Mittel aus prädiktiver Verteilung und Posteriori-Modellwahrscheinlichkeit

$$P(\Delta | D) = \sum_{k=1}^K P(\Delta | M_k, D)P(M_k | D).$$

Berücksichtigung aller Modelle

Gewichtetes Mittel aus prädiktiver Verteilung und Posteriori-Modellwahrscheinlichkeit

$$P(\Delta | D) = \sum_{k=1}^K P(\Delta | M_k, D)P(M_k | D).$$

Um die Posteriori-Verteilung auszuwerten, kann beispielsweise der Posteriori-Erwartungswert berechnet werden

$$E[\Delta | D] = \sum_{k=1}^K E[\Delta | D, M_k]P(M_k|D),$$

Einfache Grundidee

Gewichtetes Mittel über mehrere Modelle

Einbettung in Bayesianischen Kontext

Annahme von Priori-Verteilungen, Untersuchung von Posteriori-Verteilungen

Einfache Grundidee

Gewichtetes Mittel über mehrere Modelle

Einbettung in Bayesianischen Kontext

Annahme von Priori-Verteilungen, Untersuchung von Posteriori-Verteilungen

Probleme in der Umsetzung

- Integral der prädiktiven Verteilung von Δ
- Integral der marginalen Likelihood
- Identifizierung der K Modelle

- 1 Motivation
- 2 Einführung in die Bayesianische Statistik
- 3 Theorie des Bayesian Model Averaging
- 4 Implementierung im Survival-Kontext**
- 5 Anwendungsbeispiel
- 6 Zusammenfassung und Ausblick

Beschränkung auf Cox-Modelle

Betrachte Modelle einer Modellklasse, die sich nur in den aufgenommenen Kovariablen unterscheiden

Beschränkung auf Cox-Modelle

Betrachte Modelle einer Modellklasse, die sich nur in den aufgenommenen Kovariablen unterscheiden

Partial Likelihood

Besonderheit der Cox-Modelle

$$PL(\beta) = \prod_{i=1}^m \frac{\exp(X_i^T \beta)}{\sum_{j \in R_i} \exp(X_j^T \beta)}$$

$i = 1, \dots, m$	Individuen mit Ereignis
$i = m + 1, \dots, n$	Zensierte Individuen
R_i	Risk-Set zum Zeitpunkt des Ereignisses für i

Zur Erinnerung:

$$P(\Delta \mid M_k, D) = \int P(\Delta \mid \theta_k, M_k, D)P(\theta_k \mid M_k, D)d\theta_k.$$

Zur Erinnerung:

$$P(\Delta | M_k, D) = \int P(\Delta | \theta_k, M_k, D)P(\theta_k | M_k, D)d\theta_k.$$

Maximum-Likelihood-Estimator Approximation

$$P(\Delta | M_k, D) \approx P(\Delta | M_k, D, \hat{\beta}_{k,ML})$$

Ursprünglich aus der robusten Likelihood-Schätzung für Zeitreihen

Zur Erinnerung:

$$P(D | M_k) = \int P(D | \theta_k, M_k)P(\theta_k | M_k)d\theta_k$$

Zur Erinnerung:

$$P(D | M_k) = \int P(D | \theta_k, M_k)P(\theta_k | M_k)d\theta_k$$

Approximation durch das BIC

$$\log(P(D | M_k)) \approx BIC.$$

Anstelle der Gesamtzahl der Beobachtungen n wird nur die Zahl der beobachteten Ereignisse m aufgenommen

⇒ Eher grobe Approximation (Theoretischer Fehlerterm $\mathcal{O}(1)$)

Über welche Modelle soll gemittelt werden?

- Mittelung über alle möglichen Kovariablenkombinationen
- ⇒ Bei p Variablen 2^p mögliche Modelle
- ⇒ Rechentechnisch sehr aufwendig

Über welche Modelle soll gemittelt werden?

- Mittelung über alle möglichen Kovariablenkombinationen
 - ⇒ Bei p Variablen 2^p mögliche Modelle
 - ⇒ Rechentechnisch sehr aufwendig
- Mittelung nur über Modelle, die von den Daten gestützt werden
 - ⇒ Modelle mit den höchsten Posteriori-Modellwahrscheinlichkeiten

$$\mathcal{A} = \left\{ M_k : \frac{\max_l \{P(M_l | D)\}}{P(M_k | D)} \leq C \right\}$$

Schätzung der q besten Modelle für jede Modellgröße

Ohne Modelle tatsächlich zu berechnen werden die q Modelle mit der höchsten Posteriori-Modellwahrscheinlichkeit ausgegeben

⇒ Mehr Modelle identifiziert, als in \mathcal{A} enthalten

Weitere Reduktionsschritte

- Approximativer Likelihood-Quotienten Test
- Berechnung der Modelle und Ausschluss über BIC

- 1 Motivation
- 2 Einführung in die Bayesianische Statistik
- 3 Theorie des Bayesian Model Averaging
- 4 Implementierung im Survival-Kontext
- 5 Anwendungsbeispiel**
- 6 Zusammenfassung und Ausblick

Zur Erinnerung:

- Überlebenszeit-Daten mit 15 Kovariablen
- Welche Risikofaktoren wirken auf das Überleben?
- BE-Modell mit 6 Variablen `age`, `albumin`, `bili`, `edema`, `prottime`, `copper`

Zur Erinnerung:

- Überlebenszeit-Daten mit 15 Kovariablen
- Welche Risikofaktoren wirken auf das Überleben?
- BE-Modell mit 6 Variablen `age`, `albumin`, `bili`, `edema`, `prottime`, `copper`

Anwendung von Bayesian Model Averaging

Leaps-and-Bounds Algorithmus ist in Funktion `bic.surv` im R-Package BMA implementiert

⇒ Aus $2^{15} = 32768$ möglichen Modellen werden 36 Modelle identifiziert

Ausgewählte Ergebnisse

M_k	age	albumin	bili	edema	protime	copper	stage	PMW
M_1	0,03	-2,82	0,76	0,82	3,07	0,36	–	0,17
M_2	0,03	-2,47	0,75	0,82	2,67	0,35	0,24	0,07
M_3	0,03	-2,40	0,79	–	–	0,35	0,31	0,07
M_4	0,03	-3,28	0,80	–	3,74	0,35	–	0,06
M_5	0,03	-3,01	0,89	0,82	2,91	–	–	0,05
PEW	0,03	-2,78	0,79	0,74	2,43	0,25	0,10	
PEP	1	1	1	0,85	0,78	0,72	0,37	

PMW: Posteriori-Modellwahrscheinlichkeit, PEW: Posteriori-Erwartungswert, PEP: Posteriori-Effektwahrscheinlichkeit

„Analogie“ zu p-Werten

$P(\beta \neq 0)$: Wahrscheinlichkeit, dass der jeweilige Koeffizient ungleich 0 ist


⇒ Interpretation einer Wahrscheinlichkeit

⇒ Kann auch **für** $\beta = 0$ sprechen


Berechnung

Summe der Posteriori-Modellwahrscheinlichkeiten der Modelle, die den Koeffizienten enthalten und nicht auf 0 schätzen


Posteriori-Verteilung von copper




Posteriori-Verteilung von copper




Posteriori-Verteilung von copper



Posteriori-Verteilung von copper



Posteriori-Verteilung von copper



- 1 Motivation
- 2 Einführung in die Bayesianische Statistik
- 3 Theorie des Bayesian Model Averaging
- 4 Implementierung im Survival-Kontext
- 5 Anwendungsbeispiel
- 6 Zusammenfassung und Ausblick**

Bayesian Model Averaging

- berücksichtigt mehrere Modelle für die Inferenz
- kann Vorwissen berücksichtigen
- liefert bessere Ergebnisse bei der Prognose

Implementierung im Survival-Kontext

- beschränkt auf Cox-PH-Modelle
- verwendet grobe Approximationen
- berücksichtigt kein Vorwissen

⇒ Beliebtheit durch leichte Grundidee und leichte Implementierung

- Fleming, T. R. and Harrington, D. P. (1991). *Counting processes and survival analysis*, John Wiley & Sons, Hoboken.
- Held, L. (2008). *Methoden der statistischen Inferenz: Likelihood und Bayes*, Spektrum Akademischer Verlag, Heidelberg.
- Hoeting, J. A., Madigan, D., Raftery, A. E. and Volinsky, C. T. (1999). Bayesian model averaging: a tutorial, *Statistical science* **14**(4): 382–401.
- Klein, J. P. and Moeschberger, M. L. (2005). *Survival analysis: techniques for censored and truncated data*, Springer, New York.
- Raftery, A., Hoeting, J., Volinsky, C., Painter, I. and Yeung, K. Y. (2017). *BMA: Bayesian Model Averaging*. R package version 3.18.7.
URL: <https://CRAN.R-project.org/package=BMA>