

# Akaike information criterion und Bayesian information criterion

Machine Learning

Vanessa Dietze

Universität zu Köln

6. Mai 2019

# Gliederung

- 1 Motivation
- 2 Grundlagen der Informationskriterien
- 3 Akaike information criterion
- 4 Bayesian information criterion
- 5 Vergleich der Kriterien

# Motivation

- Repräsentation eines Prozesses durch statistisches Modell so gut wie nie exakt
- Finden eines „besten“ Modells
- Kriterien zur Entscheidungsfindung  $\Rightarrow$  entstanden aus der Informationstheorie
- Reduzierung des Informationsverlustes
- Je weniger Informationen verloren gehen, desto besser ist das Modell
- Kriterien, die auch für „nonnested models“ gelten

- 1 Motivation
- 2 Grundlagen der Informationskriterien**
- 3 Akaike information criterion
- 4 Bayesian information criterion
- 5 Vergleich der Kriterien

# Grundlagen

- relative Bewertung von statistischen Modellen anhand gegebener Daten
- Schätzung der verloren gegangenen Daten
- „goodness of fit“
- Strafterme für hohe Parameterwahl
- asymptotische Approximationen
- anwendbar für viele verschiedene Modellarten

- 1 Motivation
- 2 Grundlagen der Informationskriterien
- 3 Akaike information criterion**
- 4 Bayesian information criterion
- 5 Vergleich der Kriterien

# Herleitung AIC

## Definition (Kullback-Leibler Divergenz)

Sei  $y := (y_1, \dots, y_n)^T$  Vektor mit  $n$  unabhängigen zufälligen Beobachtungen mit der selben Verteilungsfunktion  $F(y)$ . Sei  $G(y)$  eine Verteilungsfunktion eines weiteren Modells. Seien  $f(y)$  und  $g(y)$  die jeweiligen Dichtefunktionen. Der Zusammenhang der beiden Funktionen  $G(y)$  und  $F(y)$  wird dargestellt durch:

$$I(f, g) := \mathbb{E}_{F(y)} \left[ \log \left( \frac{f(Y)}{g(Y)} \right) \right] = \int \log \left( \frac{f(y)}{g(y)} \right) dF(y)$$

Hierbei sei  $Y$  die Zufallsvariable zu den genutzten Beobachtungen.

Die Kullback-Leibler Information gibt an, wie viel Information verloren geht, versucht man  $F(y)$  durch  $G(y)$  zu approximieren.

Ziel: Minimierung des Informationsverlustes durch:

$$\min_{g(y)} I(f, g)$$

Die Kullback-Leibler Divergenz lässt sich auch schreiben als:

$$I(f, g) := \mathbb{E}_{F(Y)} \left[ \log \left( \frac{f(Y)}{g(Y|\theta)} \right) \right] = \mathbb{E}_{F(Y)} [\log(f(Y))] - \mathbb{E}_{F(Y)} [\log(g(Y|\theta))].$$

Sei nun  $I_{\text{rel}}(f, g) = \mathbb{E}_{F(Y)} [\log(g(Y|\theta))]$ .

Somit ist die relative Kullback-Leibler Divergenz die erwartete log-likelihood Funktion.

$$\begin{aligned} \mathbb{E}_{\hat{F}(Y)} [\log(g(Y|\hat{\theta}_{\text{MLE}}(Y)))] &= \int \log(g(y|\hat{\theta}_{\text{MLE}}(y))) d\hat{F}(y) \\ &= \frac{1}{n} \sum_{i=1}^n \log(g(y_i|\hat{\theta}_{\text{MLE}}(y))) \\ &= \frac{1}{n} \log(\hat{L}) \end{aligned}$$

Der Bias lässt sich berechnen durch

$$b(F) = \mathbb{E}_{F(Y)} \left[ \frac{1}{n} \log(\hat{L}) - \mathbb{E}_{F(Y)} [\log(g(Y|\hat{\theta}_{\text{MLE}}(Y)))] \right]$$

Somit wird die relative Kullback-Leibler Divergenz

$$\hat{l}_{\text{rel}}(f, g) = \frac{1}{n} \log(\hat{L}) - \hat{b}(F)$$

Das AIC ist nun definiert als das zweifach-negative von  $\hat{l}_{\text{rel}}(f, g)$ :

$$\text{AIC} = -2\hat{l}_{\text{rel}}(f, g) = -2 \log \hat{L} + 2\hat{b}(F)$$

Durch Berechnung des Bias lässt sich dann die folgende Identität für das AIC aufschreiben:

$$\text{AIC} = -2 \log(\hat{L}) + 2k,$$

wobei  $k$  die Anzahl der Parameter oder Terme ist.

Relative Likelihood des Modells kann angegeben werden durch:

$$\exp\left(\frac{AIC_{\min} - AIC_i}{2}\right)$$

Falls die Datenmenge zu gering ist, dann wird eine Korrektur des AIC vorgenommen:

$$AIC_c = AIC + \frac{2k^2 + 2k}{n - k - 1}$$

Wird die Datenmenge groß, dann fällt der hintere Term weg und es gilt  $AIC_c \rightarrow AIC$

- Strafterm um vor "Overfitting,, zu schützen
- Term oder Modell mit geringstem AIC wird ausgewählt

- 1 Motivation
- 2 Grundlagen der Informationskriterien
- 3 Akaike information criterion
- 4 Bayesian information criterion**
- 5 Vergleich der Kriterien

# Allgemeines

Das BIC ist definiert über:

$$\text{BIC} = k \log(n) - 2 \log(\hat{L}),$$

wobei  $\hat{L}$  die Maximum-Likelihoodfunktion ist.

- Hierbei ist zu beachten, dass  $n$  deutlich größer sein sollte als  $k$
- Größerer Strafterm als bei AIC
- für höhere Dimensionen muss eine Korrektur durchgeführt werden

Das BIC lässt sich auch über die Varianz des Fehlers definieren und lautet dann:

$$\text{BIC} = n \log(\hat{\sigma}^2) + k \log(n),$$

wobei  $\hat{\sigma}^2 = \frac{1}{n} \sum_{i=1}^n (x_i - \hat{x}_i)^2$ .

- 1 Motivation
- 2 Grundlagen der Informationskriterien
- 3 Akaike information criterion
- 4 Bayesian information criterion
- 5 Vergleich der Kriterien

# Vergleich

- BIC "bestraft,, härter als AIC (ab einer Datenmenge von  $n=8$ )
- AIC ist die Schätzung einer Konstanten plus der relativen Distanz zwischen der unbekanntem Likelihood-Funktion der Daten und der gefitteten Likelihood-Funktion des Modells
- BIC ist die Schätzung einer Funktion der Posterior-Wahrscheinlichkeiten, dass das Modell das Richtige ist
- im Falle von einfachen Modellen werden die Kriterien äquivalent zum Likelihood-Quotienten Test für bestimmte alpha

- AIC hat höhere Wahrscheinlichkeit ein zu großes Modell zu wählen, BIC ein zu geringes Modell
- AIC besser für Modell, bei dem falsch-negatives Ergebnis schlechter ist als falsch-positives
- BIC besser für Modell, bei dem falsch-positives Ergebnis genauso schlecht oder noch schlechter ist als falsch-negatives Ergebnis
- Meist besser beide Kriterien kombiniert zu verwenden

# Literatur

## Verwendete Literatur

- [HTF] Trevor Hastie Robert Tibshirani Jerome Friedman, *The Elements of Statistical Learning - Data Mining, Inference, and Prediction*, Springer Series in Statistics, Seiten 230-235, 2008
- [BA] Kenneth P. Burnham David R. Anderson, *Multimodel Inference - Understanding AIC and BIC in Model Selection*, SOCIOLOGICAL METHODS and RESEARCH, Vol. 33, No. 2, November 2004, Sage Publications
- [FFRA] Frank J. Fabozzi Sergio M. Focardi Svetlozar T. Rachev Bala G. Arshanapalli, *The Basics of Financial Econometrics: Tools, Concepts, and Asset Management Applications*, Published 2014 by John Wiley and Sons, Inc.

Danke für eure Aufmerksamkeit.