

Lösungen zu Übungsblatt 6

Aufgabe 1: Glättungsverfahren

(a) Wiederholung: Eigenschaften von B-Splines:

- $k+1$ Polynomabschnitte vom Grad k (Ordnung $k+1$)
- positive Funktionswerte der Basisfunktionen in einem durch $k+2$ Knoten aufgespannten Bereich, Null an allen anderen Stellen

⇒ Form von B-Splines 1. Grades

⇒ Form von B-Splines 2. Grades

(b) Differenzenpenalty 3. Ordnung (Herleitung):

P-Spline-Ansatz:

$$\sum_{i=1}^n \left(y_i - \sum_{j=1}^m \delta_j B_j(x_i) \right)^2 + \lambda \underbrace{\sum_{j=3+1}^m (\Delta^3 \delta_j)^2}_{\text{Differenzenpenalty 3. Ordnung}} \xrightarrow{\delta} \min$$

Andere Darstellung des Differenzen-Strafterms:

$$\sum_{j=4}^m (\Delta^3 \delta_j)^2 = \left\| \underline{\underline{D}}_3 \delta \right\|^2 = \delta^T \underline{\underline{D}}_3^T \underline{\underline{D}}_3 \delta$$

Differenzen 1. bis 3. Ordnung:

$$\begin{aligned}
 \Delta^1 \delta_j &= \delta_j - \delta_{j-1} && \text{Differenz 1. Ordnung} \\
 \Delta^2 \delta_j &= \Delta(\delta_j - \delta_{j-1}) && \text{Differenz 2. Ordnung} \\
 &= \delta_j - \delta_{j-1} - (\delta_{j-1} - \delta_{j-2}) \\
 &= \delta_j - 2\delta_{j-1} + \delta_{j-2} \\
 \Delta^3 \delta_j &= \Delta(\delta_j - 2\delta_{j-1} + \delta_{j-2}) && \text{Differenz 3. Ordnung} \\
 &= (\delta_j - 2\delta_{j-1} + \delta_{j-2}) - (\delta_{j-1} - 2\delta_{j-2} + \delta_{j-3}) \\
 &= \delta_j - 2\delta_{j-1} + \delta_{j-2} - \delta_{j-1} + 2\delta_{j-2} - \delta_{j-3} \\
 &= \delta_j - 3\delta_{j-1} + 3\delta_{j-2} - \delta_{j-3}
 \end{aligned}$$

$$\Rightarrow \left\| \underline{D}_3 \delta \right\|^2 = \left\| \begin{pmatrix} -1 & 3 & -3 & 1 & 0 & \dots & \dots \\ 0 & -1 & 3 & -3 & 1 & 0 & \dots \\ \vdots & \ddots & \ddots & \ddots & \ddots & \ddots & \ddots \\ \vdots & \dots & 0 & -1 & 3 & -3 & 1 \end{pmatrix} \begin{pmatrix} \delta_1 \\ \delta_2 \\ \vdots \\ \delta_m \end{pmatrix} \right\|^2$$

(c) Zum Output und der Graphik:

(i) Modellgleichung in Link-Form:

$$\log(\mu) = \beta_0 + f(x_{\text{time}})$$

Modellgleichung in Responseform:

$$\mu = \exp\{\beta_0 + f(x_{\text{time}})\} = \exp\{\beta_0\} \cdot \exp\{f(x_{\text{time}})\}$$

(ii) s(Zeit) ist höchst signifikant!

Sukzessive Interpretation des Outputs:

- Es wurde, wie bereits in (i) dargestellt, ein Poissonmodell mit natürlichem Link (d.h. Log-Link) gefittet.
- Das Modell besteht aus einem Intercept-Term und einem Spline. Die Parameterschätzer beider Komponenten sind höchst signifikant. Dabei ist auffällig, dass der P-Wert im Falle des Splines auf Basis eines χ^2 -Tests (als quadratischer Version des Gauß-Tests) berechnet wurde. Es wurde ein kubischer Spline (`bs="cr"`) verwendet mit 8.886 effektiven Freiheitsgraden ("`edf`") gefittet. Je niedriger die Anzahl effektiver Freiheitsgrade ist, umso glatter sieht die Splinekurve aus.
- R^2 und durch das Modell erklärte Devianz: Maße der Güte der Modellanpassung, die ein bisschen niedrig zu sein scheinen.
- UBRE-Score: Gütemaß, das anstelle des AICs berechnet wurde
- Scale est. : besagt, dass $\phi = 1$, also keine Über-/Unterdispersion angenommen wird.

- $n=1337$: Anzahl Beobachtungen (Hier: Tage, zu denen Daten vorliegen)

(iii) kurze Interpretation der Graphik:

- Fehlende Daten an manchen Tagen
- Deutlich erkennbare saisonale Schwankungen
- Insgesamt fallender Trend
- breitere Konfidenzbänder an den Rändern

(iv) Aus der Splinefunktion ablesen: $s(500) \sim 0.5$

$$\mu_{500} = \exp(0.81508) \cdot \exp(0.5) = 2.26 \cdot 1.65 = 3.7$$

Erwartete Zahl an Atemwegserkrankungen am Tag 500 liegt bei 3.7.