

# Feature Abberation at Survivaltimes Statistics

Jan Weimer

26 Januar, 2015

# Was ist Sure Independent Screening

- Ziel : Das Herausfiltern einer Obermenge der aktiven Menge
- Univariate Auswertung
- Anfälligkeit gegen Korrelationen

# Inhaltsverzeichnis

- 1 Einführung
- 2 Die Fast Statistik als Schätzer
- 3 Der FAST Algorithmus
- 4 Theoretische Rechtfertigung
- 5 Die FAST Statistik in der Praxis

# Das Modell

- $Z$   $p$ -dimensionales Kovariat
- $T$  Ausfallzeit,  $C$  Abbruchzeit
- $N(t) = \mathbf{1}_{\{T \wedge C \leq t, T \leq C\}}$  der Ausfallprozess
- $Y(t) = \mathbf{1}_{\{T \wedge C \geq t\}}$  der Aktivitätsprozess

Davon betrachten wir nun  $n$  u.i.v. Kopien  $(Z_i, T_i, C_i)_{i \in \{1, \dots, n\}}$

# Das Modell

Das Lin-Ying-Modell hat eine Hazard Rate der Form:

$$\lambda(t) = \lambda_0(t)Z^T \cdot \alpha_0$$

Die Ausfallzeit  $T$  ist also exponential verteilt mit Parameter  $\lambda$ .

# Die FAST Statistik

Wir definieren die FAST Statistik  $d$

$$d := n^{-1} \int_0^T \sum_{i=1}^n (Z_i - \bar{Z}(t)) dN_i(t),$$

wobei  $\bar{Z}$  als Durchschnitt der aktiven Kovariate definiert ist.

$$\bar{Z}(t) = \sum_{i=1}^n Z_i Y_i / \sum_{i=1}^n Y_i$$

# Die FAST Statistik

Wir definieren die FAST Statistik  $d$

$$d := n^{-1} \int_0^\tau \sum_{i=1}^n (Z_i - \bar{Z}(t)) dN_i(t) = n^{-1} \sum_{i=1}^n \mathbf{1}_{\{T_i < C_i\}} (Z_i - \bar{Z}(T \wedge C)),$$

wobei  $\bar{Z}$  als Durchschnitt der aktiven Kovariate definiert ist.

$$\bar{Z}(t) = \sum_{i=1}^n Z_i Y_i / \sum_{i=1}^n Y_i = \frac{1}{\#A_t} \sum_{i \in A_t} Z_i Y_i \quad A_t := \{i : Y_i = 1\}$$

# Die FAST Statistik als Schätzer

$$d := n^{-1} \sum_{i=1}^n \mathbf{1}_{\{T_i < C_i < \tau\}} (Z_i - \bar{Z}(T \wedge C))$$

Ist  $\alpha_k > 0$ , so fallen Objekte mit großem  $k$ -ten Merkmal schneller als solche mit kleinem.

Also ist üblicherweise  $Z_{i,k}$  größer als  $\bar{Z}_k(T_i)$  und  $d_k$  nimmt Werte größer Null an.



## Die FAST Statistik als Schätzer

$$d := n^{-1} \sum_{i=1}^n \mathbf{1}_{\{T_i < C_i < \tau\}} (Z_i - \bar{Z}(T \wedge C))$$

Ist  $\alpha_k < 0$  so fallen Objekte mit kleinem  $k$ -ten Merkmal schneller als solche mit kleinem.

Also ist üblicherweise  $Z_{i,k}$  kleiner als  $\bar{Z}_k(T_i)$  und  $d_k$  nimmt Werte kleiner Null an.

# Die FAST Statistik als Schätzer

$$d := n^{-1} \sum_{i=1}^n \mathbf{1}_{\{T_i < C_i < \tau\}} (Z_i - \bar{Z}(T \wedge C))$$

Ist  $\alpha_k = 0$  so fallen Objekte mit großem  $k$ -ten Merkmal genauso schnell aus, wie solche mit kleinem.

Also ist üblicherweise  $Z_{i,k}$  gleich  $\bar{Z}_k(T_i)$  und  $d_k$  konvergiert nach dem Gesetz der großen Zahlen gegen 0.

## Die empirische Design-Matrix

Wir definieren das empirische Äquivalent zur Designmatrix

$$D = n^{-1} \sum_{i=0}^n \int_0^{\tau} Y_i(t) \{Z_i - \bar{Z}(t)\}^{\otimes 2} dt.$$

## Schätzer für $\alpha_0$

Betrachtet man nun die Doob-Meyer Zerlegung von  $N_i$ , erhält man

$$N_i = M_i + Y(t)_i \left( \lambda_0(t) + Z^T \alpha_0 \right).$$

Integration von  $\sum_{i=1}^n Z_i - \bar{Z}(t)$  ergibt:

$$\begin{aligned} \sum_{i=1}^n \int_0^\tau Z_i - \bar{Z}(t) dN_i(t) &= \left[ \sum_{i=1}^n \int_0^\tau (Z_i - \bar{Z}(t)) * (Z_i - \bar{Z}(t))^T dt \right] \alpha_0 \\ &+ \sum_{i=1}^n \int_0^\tau Z_i - \bar{Z}(t) dM_i(t). \end{aligned}$$

# Der FAST Algorithmus

**Schritt 1** Berechne anhand der Daten die FAST Statistik  $d$ .

**Schritt 2** Wähle einen Schwellwert  $\gamma$  und erkläre alle Features  $k$  mit  $|d_k| > \gamma$  als relevant.

# Der FAST Algorithmus

**Schritt 1** Berechne anhand der Daten die FAST Statistik  $d$ .

**Schritt 2** Wähle einen Schwellwert  $\gamma$  und erkläre alle Features  $k$  mit  $|d_k| > \gamma$  als relevant.

Theoretisch kann man den Algorithmus in zwei Probleme aufteilen. Hierfür definieren wir den Erwartungswert von  $d$  für  $n$  gegen unendlich

$$\delta = E \left[ \int_0^\tau \left( Z_1 - \frac{E[Z_1 Y_1]}{E[Y_1]} \right) \mathbf{1}_{\{T_1 \leq t \wedge \tau\}} \right].$$

## Notation

Wir definieren drei Mengen von Merkmalen:

$$\begin{aligned} M^n &:= \{1 \leq k \leq p_n : \alpha_k^0 \neq 0\} && \text{die aktiven Merkmale} \\ M_\delta^n &:= \{1 \leq k \leq p_n : \delta_k \neq 0\} && \text{die FAST-aktiven Merkmale} \\ \hat{M}_d^n &:= \{1 \leq k \leq p_n : |d_k| > \gamma_n\} && \text{die aktiv geschätzten Merkmale} \end{aligned}$$

## Notation

Wir definieren drei Mengen von Merkmalen:

$M^n := \{1 \leq k \leq p_n : \alpha_k^0 \neq 0\}$  die aktiven Merkmale

$M_\delta^n := \{1 \leq k \leq p_n : \delta_k \neq 0\}$  die FAST-aktiven Merkmale

$\hat{M}_d^n := \{1 \leq k \leq p_n : |d_k| > \gamma_n\}$  die aktiv geschätzten Merkmale

Fragestellung 1: Unter welchen Voraussetzungen ist die Menge  $M^n$  der aktiven Merkmale Teilmenge der FAST-aktiven Merkmale  $M_\delta^n$ .

Fragestellung 2: Unter welchen Voraussetzungen ist die Menge  $M_\delta^n$  der FAST-aktiven Merkmale Teilmenge der aktiv geschätzten Merkmale  $\hat{M}_d^n$ .



# Annahmen 1

- 1) Die Überlebensfunktion  $\exp\left(-\int_0^t \lambda(t, \cdot) ds\right)$  ist stetig differenzierbar
- 2) Es gibt ein  $c \in \mathbb{R}^p$  :  $E[Z_1 | Z_1^T \alpha^0] = c \cdot Z_1^T \alpha^0$
- 3) Die Abbruchzeit hängt von  $T_1$  und  $Z_1$  nur durch  $Z_{1,k}$ ,  $k \notin M^n$  ab
- 4)  $Z_{1,k}$   $k \in M^n$  ist unabhängig von  $Z_{1,j}$ ,  $j \notin M^n$

## Annahmen 2

- a)  $E[Z_1, k] = 0, V[Z_1, k] = 1$
- b)  $P(Y_1(\tau) = 1) > 0$
- c)  $\text{Var}[Z_1^T \alpha^0]$  ist gleichmäßig beschränkt
- d)  $P(|Z_{1,k}| > s) \leq l_0 \exp(-l_1 s^\eta)$  für ein  $l_0, l_1, \eta > 0$  und  $s$  genügend groß.

## Lemma

Gelten Annahmen *a)* und *b)*, dann gibt es  $C_1, C_2 > 0$ , so dass für alle  $K > 0$  und  $k \in \{1, \dots, p_n\}$  gilt:

$$\begin{aligned} P[n^{\frac{1}{2}}|d_k - \delta_k| > C_1(1+t)] &\leq 10\exp(-t^2/(8K^2)) \\ &\quad + C_2\exp(-n/2) \\ &\quad + nP[|Z_{1,k}| > K] \end{aligned}$$

## Massard Concentration Theoreme

Seien  $X_1, \dots, X_n$  unabhängig mit Werten in  $\mathbb{R}^N$  so dass  $a_{i,t} < X_{i,t} < b_{i,t}$ . Definiere

$$L^2 := \sup_{1 \leq t \leq N} \sum_{i=1}^n (b_{i,t} - a_{i,t})^2 \quad Z := \sup_{t \in \{1, \dots, N\}} \sum_{i=1}^n X_{i,t}$$

dann gilt

$$P[Z \geq E[Z] + x] < \exp(-x^2/2L^2).$$

## Massard Concentration Theoreme

Für  $\tilde{Z} = \frac{1}{n} \sup \sum_{i=1}^n X_{i,t}$  und  $a_{i,t} = -K$  und  $b_{i,t} = K$  gilt

$$P \left[ n\tilde{Z} \geq nE[\tilde{Z}] + x \right] < \exp \left( \frac{-x^2}{2n(2K)^2} \right)$$

$\iff$

$$P \left[ n^{\frac{1}{2}} \tilde{Z} \geq n^{\frac{1}{2}} E[\tilde{Z}] + \tilde{x} \right] < \exp \left( \tilde{x}^2 / 8K^2 \right)$$

## Lemma

Gelten Annahmen *a)* und *b)*, dann gibt es  $C_1, C_2 > 0$ , so dass für alle  $K > 0$  und  $k \in \{1, \dots, p_n\}$  gilt:

$$\begin{aligned} P[n^{\frac{1}{2}}|d_k - \delta_k| > C_1(1+t)] &\leq 10 \exp(-t^2/(8K^2)) \\ &\quad + C_2 \exp(-n/2) \\ &\quad + nP[|Z_{1,k}| > K] \end{aligned}$$

Gilt nun außerdem Annahme *d)*, also  $P(|Z_{1,k}| > s) \leq l_0 \exp(-l_1 s^\eta)$  für ein  $l_0, l_1, \eta > 0$  so erhält man

$$nP[|Z_{1,k}| > K] \leq l_0 \exp(-l_1 * nK^\eta)$$

und kann die drei exponentiellen Raten zusammenfassen.

# Satz 1

Gelten die Annahmen 1-3 sowie a-d und außerdem

$$|\text{cov}(Z_{1_k}, Z_1^T \alpha^0)| \geq c_1 n^{-\kappa} \forall k \in M^n$$

für ein  $c_1 > 0$  und  $\kappa \in (0, \frac{1}{2})$ , dann gilt

$$M^n \subset M_\delta^n.$$

# Satz 1

Gelten die Annahmen 1-3 sowie a-d und außerdem

$$|\text{cov}(Z_{1_k}, Z_1^T \alpha^0)| \geq c_1 n^{-\kappa} \forall k \in M^n$$

für ein  $c_1 > 0$  und  $\kappa \in (0, \frac{1}{2})$ , dann gilt

$$M^n \subset M_\delta^n.$$

Wählt man nun  $\gamma_n = c_2 n^{-\kappa}$  für ein  $c_2 \in [0, \frac{c_1}{2}]$  und ist  $\log(p_n) = o(n^{(1-2\kappa)\eta/(\eta+2)})$  dann gilt auch die SIS Eigenschaft

$$\lim_{n \rightarrow \infty} P(M^n \subset \hat{M}_d^n) = 1.$$



## Satz 2

Unter Annahmen 1-4 , a-d und  $\gamma_n = \tilde{c}_2 n^{-\kappa}$  für  $\kappa < \frac{1}{2}$ ,  $\tilde{c}_2 > 0$  ,  
dann gibt es ein  $c_3 > 0$ , sodass

$$P \left[ \hat{M}_d^n \geq O \left( n^{2\kappa} \lambda_{\max} (\Sigma) \right) \right] \leq 1 - O \left( p_n \exp \left( -c_5 n^{(1-2\kappa)\eta / (\eta + 2)} \right) \right)$$

## Skalieren der FAST Statistik

Problem: Merkmale sind nicht immer zentriert und standardisiert.  
Deshalb kann man verschiedene Normierungen vornehmen:

$$\text{Ling-Ying } d_k^L Y := d_k D_{k,k}^{-1}$$

$$\text{FAST-Loss } d_k^L Y := d_k D_{k,k}^{-\frac{1}{2}}$$

$$\text{Z-FAST } d_k^L Y := d_k B_{k,k}^{-\frac{1}{2}}$$

## Satz 4

Folge T einem Modell mit einer Ausfallrate der Form  $\lambda(t, Z^T \alpha^0)$ .  
Es gelte außerdem Annahme 2 und, dass C unabhängig von T und Z ist. Verwendet man nun ein Ling Ying Modell und löst die Gleichung  $\Lambda \beta^0 = \delta$  auf und ist  $\Lambda$  nicht singular, so gibt es eine Konstante  $\nu(\mathbb{L}(Z_1^T \alpha^0), \mathbb{L}(C)) \neq 0$ , sodass

$$\beta^0 = \nu \alpha^0.$$

## Iterated SIS (ISIS)

Es folgt ein Standard ISIS Algorithmus:

- Schritt 1** Berechne die FAST Statistik  $d$  und skaliere sie mit  $D_{kk}^{-1}$ . Sei  $A_0$  die Menge der  $k_0$  relevantesten Merkmale.
- Schritt 2** Führe mit den ausgewählten Parametern eine Regression durch (z.B. Lasso, SCAD, SICA) und schreibe die übrig gebliebenen Merkmale in  $B_0$ .
- Schritt 3** Falls keine Merkmale entfernt wurden, d.h.  $B_r = B_{r-1}$  oder  $r = r_{max}$ , gebe  $B_r$  aus, sonst gehe zu Schritt 4.
- Schritt 4** (Neurekrutierung) Evaluiere die Relevanz der Merkmale, die nicht Ausgewählt wurden erneut, in dem Ling-Ying Modell ohne Penalty-Funktion, welches nur die Merkmale  $i \notin M \setminus B_R$  betrachtet.

# FAST Statistik

Quelle : Anders Gorst-Rasmussen, Thomas Scheike, Independent screening for single-index hazard rate models with ultrahigh dimensional features.