

Logistic Regression for Data w/ Rare Events

Ideen und Beweise basierend auf Paper von Wang, 2020
(arXiv:2006.00683)

Statistical Learning for Imbalanced Datasets Seminar

Jean Chammas

08.06.2021

- Haben einen Datensatz $\mathcal{D}_n = \{(x_1, y_1), (x_2, y_2), \dots, (x_n, y_n)\}$ mit n Datenpunkten, davon n_1 cases und n_0 controls.
- Es ist $n_1 \ll n_0$.
- Wir wollen eine Logistische Regression durchführen. Gängige Ansätze in der Praxis: Over- und Undersampling. Auswirkung der Ansätze auf den Schätzer im unbalancierten Fall ist aber noch unbekannt.
- \Rightarrow Das wird nun untersucht! (Müssen aber noch die mathematische Modellierung präzisieren).

Annahmen:

- $n_1/n_0 \rightarrow 0$ bzw. $n_1/n \rightarrow 0$ für $n \rightarrow \infty$.
- Es soll trotzdem $n_1 \rightarrow \infty$ für $n \rightarrow \infty$ gelten.
- Es folgt also

$$\mathbb{P}(y = 1) \rightarrow 0 \quad \text{und} \quad n\mathbb{P}(y = 1) \rightarrow \infty \quad (1)$$

Was heißt das für die Regressionsgerade?

- Es seien α_t, β_t die wahren geraden Parameter ($\alpha_t + \beta_t^T x$). Es gelte $\beta_t = \text{const.}, \forall n \in N$ und $\alpha_t \rightarrow -\infty$ mit einer passenden Rate, so dass gilt:

$$\frac{n_1}{n} = \mathbb{P}(y = 1)\{1 + o_p(1)\} = \mathbb{E} \left[\frac{\exp(\alpha_t + \beta_t^T x)}{1 + \exp(\alpha_t + \beta_t^T x)} \right] \{1 + o_p(1)\} \quad (2)$$

- Maximum-Likelihood-Ansatz: wir maximieren die Log-Likelihood Funktion

$$l(\theta) = \sum_{i=1}^n (y_i z_i^T \theta - \log(1 + \exp(z_i^T \theta))) \quad (3)$$

- Wir bezeichnen mit $\hat{\theta}$ den maximierer von (3)

- Wollen alle cases im Datensatz beibehalten und einige controls weglassen
- Definiere die Auswahlfunktion für den i -ten Datenpunkt:

$$\delta_i = y_i + (1 - y_i)I_{u_i < \pi_0}$$

wobei $u_i \sim \mathbb{U}[0, 1]$ i.i.d. sind und $\pi_0 \in [0, 1]$ gewählt werden kann.

- Maximum-Likelihood-Ansatz: wir maximieren die Log-Likelihood Funktion

$$l(\theta) = \sum_{i=1}^n \frac{\delta_i}{\pi_i} (y_i z_i^T \theta - \log(1 + \exp(z_i^T \theta))) \quad (4)$$

wobei $\pi_i = \mathbb{E}[\delta_i | \mathcal{D}_n] = y_i + (1 - y_i)\pi_0 = \pi_0 + (1 - \pi_0)y_i$.

- Wir bezeichnen mit $\hat{\theta}_{\text{under}}^w$ den Maximierer von (4)

- Wollen alle controls im Datensatz beibehalten und einige cases mehrfach zählen.
- Definiere die Auswahlfunktion für den i -ten Datenpunkt:

$$\tau_i = 1 + y_i v_i$$

wobei $v_i \sim \text{POI}(\lambda_n)$ zum Parameter λ_n i.i.d. sind.

- Maximum-Likelihood-Ansatz: wir maximieren die Log-Likelihood Funktion

$$l(\theta) = \sum_{i=1}^n \frac{\tau_i}{w_i} (y_i z_i^T \theta - \log(1 + \exp(z_i^T \theta))) \quad (5)$$

wobei $w_i = \mathbb{E}[\tau_i | \mathcal{D}_n, y_i = 1] = 1 + \lambda_n$.

- Wir bezeichnen mit $\hat{\theta}_{over}^w$ den Maximierer von (5)

Theorem 1

Es sei $\mathbb{E}[\exp(t \|x\|)] < \infty$ für alle $t > 0$, $\mathbb{E}[\exp(\beta_t^T x) z z^T]$ sei positiv definit. Es gelten weiter die Annahmen aus (1) und (2). Dann gilt falls $n \rightarrow \infty$:

$$\sqrt{n_1}(\hat{\theta} - \theta_t) \rightarrow_D \mathcal{N}(0, V_f) \quad (6)$$

mit

$$V_f = \mathbb{E}[\exp(\beta_t^T x)] M_f^{-1}$$

$$M_f = \mathbb{E}[\exp(\beta_t^T x) z z^T]$$

Theorem 2 (Undersampling)

Es sei $\mathbb{E}[\exp(t \|x\|)] < \infty$ für alle $t > 0$, $\mathbb{E}[\exp(\beta_t^T x) z z^T]$ sei positiv definit. Es gelte $c_n = \exp(\alpha_t)/\pi_0 \rightarrow c \in [0, \infty)$. Es gelten weiter die Annahmen aus (1) und (2). Dann gilt falls $n \rightarrow \infty$:

$$\sqrt{n_1}(\hat{\theta}_{\text{under}}^w - \theta_t) \rightarrow_{\mathcal{D}} \mathcal{N}(0, V_{\text{under}}^w) \quad (7)$$

mit

$$V_{\text{under}}^w = \mathbb{E} \left[\exp(\beta_t^T x) \right] M_f^{-1} M_{\text{under}}^w M_f^{-1}$$

$$M_{\text{under}}^w = \mathbb{E} \left[\exp(\beta_t^T x) (1 + c \exp(\beta_t^T x)) z z^T \right]$$

Theorem 3 (Oversampling)

Es sei $\mathbb{E}[\exp(t \|x\|)] < \infty$ für alle $t > 0$, $\mathbb{E}[\exp(\beta_t^T x) z z^T]$ sei positiv definit. Es gelte $\lambda_n \rightarrow \lambda \geq 0$. Es gelten weiter die Annahmen aus (1) und (2). Dann gilt falls $n \rightarrow \infty$:

$$\sqrt{n_1}(\hat{\theta}_{over}^w - \theta_t) \rightarrow_{\mathcal{D}} \mathcal{N}(0, V_{over}^w) \quad (8)$$

mit

$$V_{over}^w = \frac{(1 + \lambda)^2 + \lambda}{(1 + \lambda)^2} \mathbb{E}[\exp(\beta_t^T x)] M_f^{-1}$$

- Es gilt falls $c > 0$, $V_{under}^w \geq V_f$ in der Loewner Ordnung.
- Es gilt falls $\lambda \neq \{0, \infty\}$, $V_{over}^w \geq V_f$ in der Loewner Ordnung.
- Die Effizienz wird in beiden Fällen schlechter

ZGWS von Lindeberg (van der Vaart, 1998 S. 20)

Für jedes n seien $Y_{n,1}, \dots, Y_{n,k_n}$ unabhängige Zufallsvektoren mit endlicher Varianz so dass für jedes $\epsilon > 0$ gilt

$$\sum_{i=1}^{k_n} \mathbb{E} \left[\|Y_{n,i}\|^2 I_{\|Y_{n,i}\| > \epsilon} \right] \rightarrow 0 \quad \text{und}$$

$$\sum_{i=1}^{k_n} \text{Cov}(Y_{n,i}) \rightarrow \Sigma$$

Dann gilt

$$\sum_{i=1}^{k_n} (Y_{n,i} - \mathbb{E}[Y_{n,i}]) \rightarrow_{\mathcal{D}} \mathcal{N}(0, \Sigma)$$

Basic Corollary (Hjort and Pollard, 2011 S. 2)

Es sei $A_n(s)$ convex und darstellbar der Form $s^T VS + U_n^T s + C_n + r_n(s)$ wobei V symmetrisch und positiv definit ist, U_n stochastisch beschränkt, C_n beliebig, und $r_n(s) \in o_p(1)$. Dann gilt für den Minimierer α_n von A_n : α_n und der Minimierer $\beta_n = -V^{-1}U_n$ von $s^T VS + U_n^T s + C_n$ unterscheiden sich um $o_p(1)$. Gilt zusätzlich $U_n \rightarrow_D U$ so folgt $\alpha_n \rightarrow_D -V^{-1}U$.

Theorem von Slutsky (Rohde, WS2020/2021 S.58)

Gilt für die Folgen von ZVAs $A_n \rightarrow_p A$ und $B_n \rightarrow_D B$ so folgt für das Produkt: $A_n B_n \rightarrow_D AB$.

- Definiere $a_n := \sqrt{n \exp(\alpha_t)}$
- Die Annahme $\mathbb{E} [\exp(t \|x\|)] < \infty$ für $t > 0$ liefert $\mathbb{E} [\exp(t_1 \|x\|) \|z\|^{t_2}] < \infty$ mit $t_1, t_2 > 0$. Wählt man für $t_1, t_2 > 0$ $t > t_1$ und $k > t_2$ folgt die Aussage aus

$$\begin{aligned} \exp(t \|x\|) &\geq \exp(-t) \exp(t \|z\|) \\ &= \exp(-t) \exp(t_1 \|z\|) \exp((t - t_1) \|z\|) \\ &\geq \frac{\exp(-t)(t - t_1)^k}{k!} \|z\|^k \exp(t_1 \|x\|) \\ &\geq \frac{\exp(-t)(t - t_1)^k}{k!} \|z\|^{t_2} \exp(t_1 \|x\|) \end{aligned}$$

mit Wahrscheinlichkeit 1.

Es gilt $n_1 = n \exp(\alpha_t) \mathbb{E} [\exp(\beta_t^T x)] \{1 + o_p(1)\}$. Dazu betrachte man

$$\begin{aligned} \mathbb{P}(y = 1|x)(1 + \exp(\alpha_t + \beta_t^T x)) &= \exp(\alpha_t + \beta_t^T x) \\ \Rightarrow \mathbb{E} [\mathbb{P}(y = 1|x)(1 + \exp(\alpha_t + \beta_t^T x))] &= \mathbb{E} [\exp(\alpha_t + \beta_t^T x)] \\ \Rightarrow \underbrace{\mathbb{E} [\mathbb{P}(y = 1|x)]}_{= \mathbb{P}(Y=1) = \mathbb{E}[Y]} \{1 + o_p(1)\} &= \exp(\alpha_t) \mathbb{E} [\exp(\beta_t^T x)] \end{aligned}$$

Gleichzeitig gilt $\frac{n_1}{n} = \frac{\sum_{i=1}^n Y_n}{n} \rightarrow_p \mathbb{E}[Y]$. Einsetzen liefert

$$\begin{aligned}\frac{n_1}{n} \{1 + o_p(1)\} \{1 + o_p(1)\} &= \exp(\alpha_t) \mathbb{E} \left[\exp(\beta_t^T x) \right] \\ \Rightarrow n_1 &= n \exp(\alpha_t) \mathbb{E} \left[\exp(\beta_t^T x) \right] \{1 + o_p(1)\}\end{aligned}$$

Beweis Idee:

- Schreibe Loglikelihood-Funktion um in die Form $\frac{1}{2}s^T V s + B_n^T s + C_n + r_n(s)$, V symmetrisch und $r_n(s) \in o_{\mathbb{P}}(1)$
- ZGW Linderberg liefert $B_n \rightarrow_{\mathcal{D}} \mathcal{N}(0, W_1)$
- Zeigen direkt $V \rightarrow_p W_2$
- Basic corollary und Slutsky liefern die Aussage

Beweis Idee:

- **Schreibe Loglikelihood-Funktion um in die Form**
 $\frac{1}{2}s^T V s + B_n^T s + C_n + r_n(s)$, V **symmetrisch** und $r_n(s) \in o_{\mathbb{P}}(1)$
- ZGW Linderberg liefert $B_n \rightarrow_{\mathcal{D}} \mathcal{N}(0, W_1)$
- Zeigen direkt $V \rightarrow_p W_2$
- Basic corollary und Slutsky liefern die Aussage

- $\hat{\theta}$ maximiert

$$l(\theta) = \sum_{i=1}^n \left((\alpha + \beta x_i^T) y_i - \log(1 + \exp(\alpha + \beta x_i^T)) \right) \quad (9)$$

- Somit maximiert $u_n = a_n(\hat{\theta} - \theta_t)$

$$\gamma(u) = l(\theta_t + a_n^{-1}u) - l(\theta_t) \quad (10)$$

- Wir bilden die Taylorentwicklung von γ bei $u = 0$ bis zur zweiten Ordnung:

$$\gamma(u) = a_n^{-1} u^T \dot{l}(\theta_t) + 0.5 a_n^{-2} \sum_{i=1}^n \phi_i(\theta_t + a_n \dot{u})(z_i^T u)^2 \quad (11)$$

wobei $\phi_i(\theta) = p_i(\theta)(1 - p_i(\theta))$, \dot{l} der Gradient der Likelihood Funktion ist und $\dot{u} \in [0, u]$.

- Es folgt mit der Kettenregel :

$$j(\theta) = \sum_{i=1}^n z_i y_i - z_i \underbrace{\frac{\exp(\alpha + \beta x_i^T)}{1 + \exp(\alpha + \beta x_i^T)}}_{=p_i(\theta)} \quad (12)$$

- Mit der Produktregel folgt $\dot{p}_i(\theta) = p_i(\theta)(1 - p_i(\theta))z_i$ und somit :

$$\frac{d^2}{d\theta^2} l(\theta) = - \sum_{i=1}^n \phi_i(\theta) z_i z_i^T \quad (13)$$

- Ziel ist es, zu zeigen dass

$$a_n^{-1}j(\theta) \rightarrow_{\mathcal{D}} \mathcal{N}(0, M_f) \quad (14)$$

mit $M_f = \mathbb{E} [\exp(\beta_t^T x) z z^T]$.

- Desweiteren wollen wir

$$- a_n^{-2} \sum_{i=1}^n \phi_i(\theta_t + a_n^{-1} \dot{u}) z_i z_i^T \rightarrow_p M_f \quad (15)$$

für alle $\dot{u} \in [0, u]$.

Beweis Idee:

- Schreibe Loglikelihood-Funktion um in die Form $\frac{1}{2}s^T V s + B_n^T s + C_n + r_n(s)$, V symmetrisch und $r_n(s) \in o_{\mathbb{P}}(1)$
- **ZGW Linderberg liefert** $B_n \rightarrow_{\mathcal{D}} \mathcal{N}(0, W_1)$
- Zeigen direkt $V \rightarrow_p W_2$
- Basic corollary und Slutsky liefern die Aussage

Wir zeigen zuerst (14) und überprüfen dazu die Voraussetzungen.

- Es gilt $\mathbb{E}[(y_i - p_i)z_i] = \mathbb{E}[\mathbb{E}[(y_i - p_i)z_i|z_i]] = 0$. Linearität liefert $\mathbb{E}[a_n^{-1}j(\theta_t)] = 0$.
- Für die Varianz gilt

$$\begin{aligned}V(a_n^{-1}j(\theta_t)) &= a_n^{-2} \sum_{i=1}^n V((y_i - p_i)z_i) \\&= a_n^{-2} \sum_{i=1}^n \mathbb{E}[(y_i - p_i)^2 z_i z_i^T] \\&= a_n^{-2} \sum_{i=1}^n \mathbb{E}[\mathbb{E}[(y_i - p_i)^2|z_i] z_i z_i^T]\end{aligned}$$

$$\begin{aligned}
&= a_n^{-2} \sum_{i=1}^n \mathbb{E}[\mathbb{E}[(1 - p_i)^2 l_{y_i=1} | z_i] z_i z_i^T] + \mathbb{E}[\mathbb{E}[p_i^2 l_{y_i=0} | z_i] z_i z_i^T] \\
&= a_n^{-2} \sum_{i=1}^n \mathbb{E}[(1 - p_i)^2 \underbrace{\mathbb{E}[l_{y_i=1} | z_i]}_{=p_i} z_i z_i^T] + \mathbb{E}[p_i^2 \underbrace{\mathbb{E}[l_{y_i=0} | z_i]}_{=(1-p_i)} z_i z_i^T] \\
&= a_n^{-2} n \mathbb{E}[p_i(1 - p_i) z_i z_i^T] \\
&= a_n^{-2} n \exp(\alpha_t) \mathbb{E} \left[\frac{\exp(\beta_t^T x)}{(1 + \exp(\alpha_t + \beta_t x_i^T))^2} z z^T \right] \\
&= \mathbb{E} \left[\frac{\exp(\beta_t^T x)}{(1 + \exp(\alpha_t + \beta_t x_i^T))^2} z z^T \right]
\end{aligned}$$

- Wir bemerken dass

$$\frac{\exp(\beta_t^T x)}{(1 + \exp(\alpha_t + \beta_t x^T))^2} z z^T \xrightarrow{f.s.} \exp(\beta_t^T x) z z^T$$

- Weiter gilt $\frac{\exp(\beta_t^T x)}{(1 + \exp(\alpha_t + \beta_t x^T))^2} \|z\|^2 \leq \exp(\beta_t^T x) \|z\|^2$ und

$$\mathbb{E} \left[\exp(\beta_t^T x) \|z\|^2 \right] < \infty$$

- Dominierte Konvergenz liefert also

$$V(a_n^{-1} j(\theta_t)) = \mathbb{E} \left[\frac{\exp(\beta_t^T x)}{(1 + \exp(\alpha_t + \beta_t x^T))^2} z z^T \right] \rightarrow \mathbb{E} \left[\exp(\beta_t^T x) z z^T \right]$$

Wir zeigen nun die Lindeberg-Bedingung. Sei $\epsilon > 0$:

$$\begin{aligned} & \sum_{i=1}^n \mathbb{E} \left[\|(y_i - p_i) z_i\|^2 I_{\|(y_i - p_i) z_i\| \geq \epsilon a_n} \right] \\ &= n \mathbb{E} \left[\|(y - p) z\|^2 I_{\|(y - p) z\| \geq \epsilon a_n} \right] \\ &= n \left(\mathbb{E} \left[\mathbb{E} [(1 - p)^2 I_{y=1} | z] \|z\|^2 I_{\|(1-p)z\| \geq \epsilon a_n} \right] \right. \\ & \quad \left. + \mathbb{E} \left[\mathbb{E} [p^2 I_{y=0} | z] \|z\|^2 I_{\|(-p)z\| \geq \epsilon a_n} \right] \right) \end{aligned}$$

$$\begin{aligned}
&= n \left(\mathbb{E} \left[p(1-p)^2 \|z\|^2 I_{\|(1-p)z\| \geq \epsilon a_n} \right] + \mathbb{E} \left[p^2(1-p) \|z\|^2 I_{\|pz\| \geq \epsilon a_n} \right] \right) \\
&\leq n \left(\mathbb{E} \left[p \|z\|^2 I_{\|(1-p)z\| \geq \epsilon a_n} \right] + \mathbb{E} \left[p^2 \|z\|^2 I_{\|pz\| \geq \epsilon a_n} \right] \right) \\
&\leq a_n^2 \mathbb{E} \left[\exp(\|\beta_t\| \|x\|) \|z\|^2 I_{\|z\| \geq \epsilon a_n} \right] \\
&\quad + a_n^2 \mathbb{E} \left[\exp(\|\beta_t\| \|x\|) \|z\|^2 I_{\|z\| \geq \epsilon a_n} \right] \\
&= o(a_n^2)
\end{aligned}$$

Beweis Idee:

- Schreibe Loglikelihood-Funktion um in die Form $\frac{1}{2}s^T V s + B_n^T s + C_n + r_n(s)$, V symmetrisch und $r_n(s) \in o_{\mathbb{P}}(1)$
- ZGW Linderberg liefert $B_n \rightarrow_{\mathcal{D}} \mathcal{N}(0, W_1)$
- **Zeigen direkt** $V \rightarrow_p W_2$
- Basic corollary und Slutsky liefern die Aussage

Es bleibt Gl.(15) zu zeigen:

$$a_n^{-2} \sum_{i=1}^n \phi_i(\theta_t + a_n^{-1} \dot{u}) z_i z_i^T \rightarrow_p M_f$$

für alle $\dot{u} \in [0, u]$.

- Dazu zeigen wir zuerst

$$\left| a_n^{-2} \sum_{i=1}^n \phi_i(\theta_t + a_n^{-1} \dot{u}) \|z_i\|^2 - a_n^{-2} \sum_{i=1}^n \phi_i(\theta_t) \|z_i\|^2 \right| \in o_p(1)$$

- Nutzen anschließend $a_n^{-2} \sum_{i=1}^n \phi_i(\theta_t) z_i z_i^T \rightarrow_p \mathbb{E} [\exp(\beta_t x) z z^T]$ um insgesamt Gl.(15) zu erhalten.
- Wegen $A \rightarrow_p B$, $B \rightarrow_p C \Rightarrow A \rightarrow_p C$ gilt dann die Aussage

Es gilt

$$\begin{aligned} & \left| a_n^{-2} \sum_{i=1}^n \phi_i(\theta_t + a_n^{-1} \dot{\vartheta}) \|z_i\|^2 - a_n^{-2} \phi_i(\theta_t) \|z_i\|^2 \right| \\ & \leq a_n^{-2} \sum_{i=1}^n \left| \underbrace{\phi_i(\theta_t + a_n^{-1} \dot{\vartheta})}_{=\phi_i(\theta_t) + a_n^{-1} \dot{\vartheta} \phi_i(\theta_t + a_n^{-1} \bar{u})} - \phi_i(\theta_t) \right| \|z_i\|^2 \end{aligned}$$

mit $\bar{u} \in [0, \dot{\vartheta}]$.

Da $\dot{\phi}_i = \dot{p}_i(1 - p_i) + p_i(1 - \dot{p}_i) = z_i(p_i(1 - p_i)^2 - p_i^2(1 - p_i)) \leq z_i p_i$ gilt, folgt

$$\begin{aligned} & \leq \|a_n^{-1} \dot{\vartheta}\| a_n^{-2} \sum_{i=1}^n p_i(\theta_t + a_n^{-1} \bar{u}) \|z_i\|^3 \\ & = \frac{\|a_n^{-1} \dot{\vartheta}\|}{n} \sum_{i=1}^n \frac{\exp(\beta_t^T x_i + a_n^{-1} \bar{u}^T z_i)}{(1 + \exp(\theta_t^T z_i + a_n^{-1} \bar{u}^T z_i))^2} \|z_i\|^3 \end{aligned}$$

$$\begin{aligned} &\leq \frac{\|a_n^{-1} \dot{u}\|}{n} \sum_{i=1}^n \exp((\|\beta_t\| \|\bar{u}\|)(1 + \|x_i\|)) \|z_i\|^3 \\ &= o_p(1) \end{aligned}$$

Es gilt zusätzlich

$$\begin{aligned} a_n^{-2} \sum_{i=1}^n \phi_i(\theta_t) z_i z_i^T &= \frac{1}{n \exp(\alpha_t)} \sum_{i=1}^n \frac{\exp(\alpha_t + \beta_t^T x_i)}{1 + \exp(\alpha_t + \beta_t^T x_i)} z_i z_i^T \\ &= \frac{1}{n} \sum_{i=1}^n \frac{\exp(\beta_t^T x_i)}{1 + \exp(\alpha_t + \beta_t^T x_i)} z_i z_i^T \end{aligned}$$

Schwaches Gesetz liefert:

$$= \mathbb{E} \left[\frac{\exp(\beta_t^T x_i)}{1 + \exp(\alpha_t + \beta_t^T x_i)} z_i z_i^T \right] + o_p(1)$$

Majorisierte Konvergenz liefert

$$= \underbrace{\mathbb{E} \left[\exp(\beta_t^T x_i) z_i z_i^T \right]}_{=M_f} + o_p(1)$$

Beweis Idee:

- Schreibe Loglikelihood-Funktion um in die Form $\frac{1}{2}s^T V s + B_n^T s + C_n + r_n(s)$, V symmetrisch und $r_n(s) \in o_{\mathbb{P}}(1)$
- ZGW Linderberg liefert $B_n \rightarrow_{\mathcal{D}} \mathcal{N}(0, W_1)$
- Zeigen direkt $V \rightarrow_p W_2$
- **Basic corollary und Slutsky liefern die Aussage**

Als letztes kombinieren wir die obigen Resultate. Gl. (14) und (15) liefern folgende Darstellung von γ :

$$\gamma(u) = 0.5u^T M_f u + a_n^{-1} j(\theta)u + o_p(1)$$

- Da $a_n^{-1} j(\theta) \rightarrow_D \mathcal{N}(0, M_f)$, liefert das "Basic Corollary"

$$a_n(\hat{\theta} - \theta_t) = \underbrace{M_f^{-1} a_n^{-1} j(\theta)}_{\sim \mathcal{N}(0, M_f^{-1})} + o_D(1)$$

- Wegen der Vorüberlegung gilt aber

$$a_n = \sqrt{n \exp(\alpha_t)} = \sqrt{\frac{n_1}{\mathbb{E}[\exp(\beta_t^T x_i)](1 + o_p(1))}} \text{ und es folgt somit}$$

$$\sqrt{n_1}(\hat{\theta} - \theta_t) = \underbrace{\sqrt{\mathbb{E}[\exp(\beta_t^T x_i)]} M_f^{-1} a_n^{-1} j(\theta)}_{\sim \mathcal{N}(0, \mathbb{E}[\exp(\beta_t^T x_i)] M_f^{-1})} (1 + o_p(1)) \quad (16)$$

Beweis Idee ist identisch zu Theorem 1!

- Schreibe Loglikelihood-Funktion um in die Form $\frac{1}{2}s^T Vs + B_n^T s + C_n + r_n(s)$, V symmetrisch und $r_n(s) \in o_{\mathbb{P}}(1)$
- ZGW Linderberg liefert $B_n \rightarrow_{\mathcal{D}} \mathcal{N}(0, W_1)$
- Zeigen direkt $V \rightarrow_p W_2$
- Basic corollary und Slutsky liefern die Aussage

Lassen den Beweis weg.

- Wir haben gesehen, dass die Grenzverteilungen mit einer Geschwindigkeit von $\frac{1}{\sqrt{n_1}}$ erreicht werden.
- Dies impliziert eine Inhomogene "Informationskonzentration" in den Daten (seltene Cases enthalten mehr "Information" als Controls)
- Subsampling verändert dementsprechend den Informationsinhalt des Datensatzes kaum und liefert eine gute Effizienz
- Oversampling verfälscht signifikant den Informationsinhalt des Datensatzens und liefert eine schlechtere Effizienz

- Hjort, Nils Lid and David Pollard (July 2011). “Asymptotics for minimisers of convex processes”. In: arXiv: 1107.3806 [math.ST].
- Rohde, Angelike (WS2020/2021). *Wahrscheinlichkeitstheorie Skript*.
- Van der Vaart, A. W. (1998). *Asymptotic Statistics*.
- Wang, HaiYing (June 2020). “Logistic Regression for Massive Data with Rare Events”. In: arXiv: 2006.00683 [stat.ML].