

---

# More Efficient Estimation for Logistic Regression with Optimal Subsamples

Nils Kornacker

Diese Seminararbeit dient dazu den Zuhörern eine Übersicht über die wichtigsten Lemmata und Theoreme aus [Wan19] sowie insbesondere alle dort nicht explizit genannten aber nützlichen Lemmata zu geben. Zusätzlich wurde eine Symbolübersicht erstellt.

## Inhaltsverzeichnis

<b>1</b>	<b>Vorbereitende Lemmata</b>	<b>2</b>
<b>2</b>	<b>Lemmata und Theoreme aus [Wan19]</b>	<b>3</b>
<b>3</b>	<b>Beweis von Lemma 4</b>	<b>7</b>
<b>4</b>	<b>Symbolübersicht</b>	<b>9</b>
	<b>Literatur</b>	<b>11</b>

# 1 Vorbereitende Lemmata

Im Folgenden seien  $(X_n)_{n \in \mathbb{N}}$  und  $X$   $\mathbb{R}^k$ -wertige Zufallsvariablen.

**v.Definition 1.** ( $o_P(r_n), O_P(r_n)$ , S.12 in [van98])

$$\begin{aligned} X_n = o_P(1) &\Leftrightarrow X_n \rightarrow_P 0 \\ X_n = O_P(1) &\Leftrightarrow \forall \varepsilon > 0 \exists M : \sup_n \mathbf{P}(\|X_n\| > M) < \varepsilon \\ X_n = o_P(r_n) &\Leftrightarrow X_n = r_n o_P(1) \\ X_n = O_P(r_n) &\Leftrightarrow X_n = r_n O_P(1) \end{aligned}$$

**v.Definition 2.** (S. 7 in [Wan19])

$X_n = O_{P|\mathcal{D}_N}(a_n) \Leftrightarrow$  Für alle  $\varepsilon > 0$  gibt es ein  $\delta_\varepsilon$ , so dass für  $n, N \rightarrow \infty$

$$\mathbf{P}(\sup_n \mathbf{P}(\|X_n\| > a_n \delta_\varepsilon | \mathcal{D}_N) \leq \varepsilon) \rightarrow 1.$$

**v.Lemma 1.** (Continuous Mapping, 2.3 in [van98])

Sei  $g : \mathbb{R}^k \mapsto \mathbb{R}^m$  stetig in jedem Punkt von einer Menge  $C$  so, dass  $\mathbf{P}(X \in C) = 1$ . Es gilt:

$$X_n = X + o_P(1) \Rightarrow g(X_n) = g(X) + o_P(1).$$

**v.Lemma 2.** (Prohorov, 2.4 in [van98])

Wenn  $X_n \rightsquigarrow X$ , dann ist  $X_n = O_P(1)$ .  $\rightsquigarrow$  meint Konvergenz in Verteilung.

**v.Lemma 3.** (2.7 in [van98])

Sei  $c$  eine Konstante:  $X_n = c + o_P(1) \Leftrightarrow X_n \rightsquigarrow c$ .

**v.Lemma 4.** (Slutsky, 2.8 in [van98])

Seien  $X_n \rightsquigarrow X$  und  $Y_n \rightsquigarrow c$ ,  $c$  eine Konstante,  $c, X_n, Y_n, X$  konform Matrixwertig (dies schließt Vektor- und Skalarwertig ein).

$$\begin{aligned} X_n + Y_n &\rightsquigarrow X + c \\ Y_n X_n &\rightsquigarrow cX \\ Y_n^{-1} X_n &\rightsquigarrow c^{-1}X, \text{ gegeben } c \text{ invertierbar.} \end{aligned}$$

**v.Lemma 5.** (Lemma 2.1 in [Mus88])

Sei  $C \subset \mathbb{R}^k$  eine konvexe Borelmenge und  $g$  eine messbare konvexe Funktion von  $C$  nach  $(-\infty, \infty]$  so, dass  $C' = \{x \in C : g(x) < \infty\} \neq \emptyset$ . Für  $i = 1, \dots, k$  sei  $X_i$  eine reellwertige messbare Funktion auf  $\Omega$  ( $(\Omega, \mathcal{A}, \mathbf{P})$  ein Wahrscheinlichkeitsraum) mit  $\mathbf{E}[|X_i|] < \infty$ . Ist  $X(\omega) \in C$  für alle  $\omega \in \Omega$ , wobei  $X = (X_1, \dots, X_k)$ , so gilt

$$g(\mathbf{E}[X|\mathcal{F}]) \leq \mathbf{E}[g(X)|\mathcal{F}] \text{ f.s. für alle } \mathcal{F} = \sigma(\mathcal{F}) \subset \mathcal{A}.$$

**v.Lemma 6.** (Theorem 1.3.6 in [Ser02])

Seien  $X_n = X + o_P(1)$ ,  $\|X_n\| \leq \|Y\|$  f.s.  $\forall n$  und  $\mathbf{E}[\|Y\|^r] < \infty$ . Dann ist  $X_n \rightarrow_{\mathcal{L}^r} X$ .

**v.Theorem 1.** (Lindeberg-Feller Theorem 2.27 in [van98])

Seien für  $n \in \mathbb{N}$   $X_{n,1}, \dots, X_{n,k_n}$  unabhängige (zufällige) Vektoren mit endlichen Varianzen, sodass

$$\begin{aligned} \sum_{i=1}^{k_n} \mathbf{E}[\|X_{n,i}\|^2 I(\|X_{n,i}\| > \varepsilon)] &\rightarrow 0 \quad \forall \varepsilon > 0, \\ \sum_{i=1}^{k_n} \mathbf{Cov}[X_{n,i}] &\rightarrow \Sigma. \end{aligned}$$

Dann gilt  $\sum_{i=1}^{k_n} (X_{n,i} - \mathbf{E}[X_{n,i}]) \rightsquigarrow \mathbb{N}(0, \Sigma)$ .

## 2 Lemmata und Theoreme aus [Wan19]

**Annahmen.**  $\mathbf{E}[\phi(\beta_t)h(x)xx^T]$  ist endlich und positiv-definit. (1)

$$\mathbf{E}[\|x\|^2 h^2(x)] < \infty, \quad \mathbf{E}[\|x\|^2 h(x)] < \infty. \quad (2)$$

$$n\mathbf{E}[h(x)I(\|x\|^2 > n)] \xrightarrow{n \rightarrow \infty} 0. \quad (3)$$

Zusätzlich:  $h(x) \stackrel{f.s.}{>} 0$  integrierbar (Theorem 1,3,5, Lemma 3,4).

**Lemma 1.** (Lemma 28 in [Wan19])

Seien  $v_1, \dots, v_N$  i.i.d. Vektoren mit selber Verteilung wie  $v$ , sowie  $g_{1N}$  eine beschränkte und  $g_2$  eine von  $N$  unabhängige Funktion. Wenn  $g_{1N}(v) = o_P(1)$  und  $\mathbf{E}[\|g_2(v)\|] < \infty$ , dann

$$\frac{1}{N} \sum_{i=1}^N g_{1N}(v_i)g_2(v_i) = o_P(1).$$

**Lemma 2.** (Lemma 29 in [Wan19])

Sei  $\eta_i = |\psi_i(\hat{\beta}_0)|\psi_i(\beta_t - \hat{\beta}_0)h(x_i)x_i$ , wobei  $\psi_i(\beta) = y_i - p(x_i, \beta)$ . Unter Annahmen 1,2 und bedingt auf den konsistenten Schätzer  $\hat{\beta}_0$ , wenn  $n_0/\sqrt{N} \rightarrow 0$ , dann

$$\sqrt{N}(\hat{\beta}_{wMLE} - \beta_t) = \frac{\Sigma_{\beta_t}}{2\mathbf{E}[\phi(\beta_t)h(x)]} \frac{1}{\sqrt{N}} \sum_{i=1}^N \eta_i + o_P(1)$$

wobei obiges gegen eine Normalverteilung mit Erwartungswertvektor 0 und Kovarianzmatrix  $\mathbf{E}[\phi(\beta_t)h(x)xx^T]^{-1}\mathbf{E}[\phi(\beta_t)h^2(x)xx^T]\mathbf{E}[\phi(\beta_t)h(x)xx^T]^{-1}$  konvergiert, für  $n_0$  und  $N$  gegen unendlich.

**Bemerkung.** Lemma 3 & 5 und Theorem 1 & 2 benötigen vermutlich die Voraussetzung  $n_0/\sqrt{N} \rightarrow 0$  oder  $\hat{\beta}_0$  unabhängig von  $\mathcal{D}_N$  ebenso.

**Basic Corollary.** (Basic Corollary in [HP11])

Sei  $A_n(s) = \frac{1}{2}s^T V s + U_n^T s + C_n + R_n(s)$  eine Folge von konvexen Funktionen, wobei  $V$  symmetrisch und positiv definit sei,  $U_n = O_P(1)$ ,  $C_n$  beliebig und  $R_n(s) = o_P(1)$  für alle  $s$ . Dann gilt für  $\alpha_n$ , das arg min von  $A_n$ , dass  $\alpha_n = \beta_n + o_P(1)$ , wobei  $\beta_n = -V^{-1}U_n$  das arg min von  $\frac{1}{2}s^T V s + U_n^T s + C_n$ . Wenn zusätzlich  $U_n \rightsquigarrow U$ , dann  $\alpha_n \rightsquigarrow -V^{-1}U$ .

Ist  $A_n(s) = \frac{1}{2}s^T V_n s + U_n^T s + C_n + R_n(s)$  konvex,  $V_n$  positiv semidefinit, symmetrisch mit  $V_n = V + o_P(1)$ ,  $V$  positiv definit, hält das Ergebnis mit  $V_n$  ebenso ( $R_n(s)' = R_n(s) + \frac{1}{2}s^T (V - V_n)s$ ).

**Lemma 3.** (Lemma 30 in [Wan19])

Sei

$$\dot{\lambda}_{uw}^*(\beta_t) = \sum_{i=1}^n (y_i^* - p_i^*(\beta_t - \hat{\beta}_0))x_i^*.$$

Unter Annahmen 1,2, bedingt auf  $\mathcal{D}_N$  und den konsistenten Schätzer  $\hat{\beta}_0$ , wenn  $n_0, n$  und  $N$  gegen unendlich streben

$$\frac{\dot{\lambda}_{uw}^*(\beta_t)}{\sqrt{n}} - \frac{\sqrt{n} \sum_{i=1}^N \eta_i}{N\Psi_N(\hat{\beta}_0)} \rightsquigarrow \mathbf{N}(0, \Sigma_{\beta_t}^{-1}),$$

wobei  $\Psi_N(\beta) = N^{-1} \sum_{i=1}^N |y_i - p(x_i, \beta)|h(x_i)$ .

**Lemma 4.** (Lemma 31 in [Wan19])

Unter Annahmen 1-3, wenn  $n_0, n$  und  $N$  gegen unendlich streben und  $s_n = o_P(1)$

$$\frac{1}{n} \sum_{i=1}^n \phi_i^*(\beta_t - \hat{\beta}_0 + s_n) \|x_i^*\|^2 - \sum_{i=1}^N \pi_i(\hat{\beta}_0) \phi_i(\beta_t - \hat{\beta}_0) \|x_i\|^2 = o_P(1).$$

Ebenso gilt

$$\frac{1}{n} \sum_{i=1}^n \phi_i^*(\beta_t - \hat{\beta}_0 + s_n) x_i^* x_i^{*T} - \sum_{i=1}^N \pi_i(\hat{\beta}_0) \phi_i(\beta_t - \hat{\beta}_0) x_i x_i^T = o_P(1).$$

Für den Beweis siehe hier in diesem Blatt S.7.

**Theorem 1.** (Theorem 1 in [Wan19])

Unter Annahmen 1-3, bedingt auf  $\mathcal{D}_N$ , wenn  $\hat{\beta}_0$  konsistent,  $n_0, n, N \rightarrow \infty$

$$\sqrt{n}(\hat{\beta}_{uw} - \hat{\beta}_{wMLE}) \rightsquigarrow \mathbb{N}(0, \Sigma_{\beta_t}).$$

Wenn  $n/N \rightarrow 0$ , dann

$$\sqrt{n}(\hat{\beta}_{uw} - \beta_t) \rightsquigarrow \mathbb{N}(0, \Sigma_{\beta_t}).$$

$\hat{\beta}_{wMLE} = \arg \max_{\beta} \sum_{i=1}^N |y_i - p(x_i, \hat{\beta}_0)| h(x_i) [y_i x_i^T (\beta - \hat{\beta}_0) - \log(1 + e^{x_i^T (\beta - \hat{\beta}_0)})]$  ist ein gewichteter MLE,  $\Sigma_{\beta} = \left[ \frac{\mathbf{E}[\phi(\beta) h(x) x x^T]}{4\Phi(\beta)} \right]^{-1}$  und  $\Phi(\beta) = \mathbf{E}[\phi(\beta) h(x)]$ .

Wenn  $\hat{\beta}_0$  uniform aus Stichprobe der Größe  $n_0$  gesampelt wurde mit  $n_0/\sqrt{N} = o(1)$  oder  $\hat{\beta}_0$  unabhängig von  $\mathcal{D}_N$ , dann gilt

$$\sqrt{N}(\hat{\beta}_{wMLE} - \beta_t) \rightsquigarrow \mathbb{N}(0, \Sigma_{wMLE}),$$

wobei  $\Sigma_{wMLE} = [\mathbf{E}[\phi(\beta_t) h(x) x x^T]]^{-1} \mathbf{E}[\phi(\beta_t) h^2(x) x x^T] [\mathbf{E}[\phi(\beta_t) h(x) x x^T]]^{-1}$ .

**Proposition 1.** (Proposition 4 in [Wan19])

Wenn  $M, V_c^{OS}$  und  $\Sigma_{\beta_t}$  endliche und positiv definite Matrizen sind, dann gilt

$$\Sigma_{\beta_t} \leq V^{OS}$$

in der Loewner-Ordnung [A und B positiv semidefinit:  $A \geq B \Leftrightarrow A - B$  ist positiv semidefinit]. Für  $h(x) = 1$  gilt Gleichheit.

**Bemerkung.**  $A \leq B \Rightarrow C^T A C \leq C^T B C$

**Lemma 5.** (Lemma 32 in [Wan19])

Sei

$$\dot{\lambda}_p(\beta_t) = \sum_{i=1}^N \delta_i^{\hat{\beta}_0} (n\pi_i^p(\hat{\beta}_0) \vee 1) (y_i - p(x_i, \beta_t - \hat{\beta}_0)) x_i.$$

Unter Annahmen 1 und 2 und bedingt auf  $\mathcal{D}_N$  sowie die konsistenten Schätzer  $\hat{\beta}_0$  und  $\hat{\Psi}_0$  gilt, wenn  $n/N \rightarrow 0$ , dass

$$\frac{\dot{\lambda}_p(\beta_t)}{\sqrt{n}} - \frac{\sqrt{n} \sum_{i=1}^N \eta_i}{N \hat{\Psi}_0} \rightsquigarrow \mathbb{N}(0, \Sigma_{\beta_t}^{-1}).$$

Konvergiert  $n/N$  gegen  $\rho \in (0, 1)$ , dann

$$\frac{\dot{\lambda}_p(\beta_t)}{\sqrt{n}} - \frac{\sqrt{n} \sum_{i=1}^N \eta_i}{N \hat{\Psi}_0} \rightsquigarrow \mathbb{N}(0, \Lambda_{\rho}).$$

**Lemma 6.** (Lemma 33 in [Wan19])

Unter Annahmen 1 und 2, wenn  $n_0, n, N \rightarrow \infty$ , und  $s_n = o_P(1)$

$$\frac{1}{n} \sum_{i=1}^N \delta_i^{\hat{\beta}_0} (n\pi_i^p(\hat{\beta}_0) \vee 1) \phi_i(\beta_t - \hat{\beta}_0 + s_n) \|x_i\|^2 - \sum_{i=1}^N \pi_i^p(\hat{\beta}_0) \phi_i(\beta_t - \hat{\beta}_0) \|x_i\|^2 = o_P(1).$$

**Theorem 2.** (Theorem 6 in [Wan19])

Es gelten Annahmen 1 und 2, und  $\hat{\beta}_0$  sei konsistenter Schätzer für  $\beta_t$ . Dann ist bedingt auf  $\mathcal{D}_N$  für  $n_0, n$  und  $N \rightarrow \infty$  mit  $n/N \rightarrow 0$

$$\sqrt{n}(\hat{\beta}_p - \beta_t) \rightsquigarrow \mathbb{N}(0, \Sigma_{\beta_t}).$$

Ist  $n/N \rightarrow \rho \in (0, 1)$ , so gilt

$$\sqrt{n}(\hat{\beta}_p - \hat{\beta}_{wMLE}) \rightsquigarrow \mathbb{N}(0, \Sigma_{\beta_t} \Lambda_\rho \Sigma_{\beta_t}),$$

mit  $\Lambda_\rho = \mathbf{E}[|\psi(\beta_t)|h(x)(\Psi(\beta_t) - \rho|\psi(\beta_t)|h(x))_+ xx^T] / (4\Psi^2(\beta_t))$ .

**Proposition 2.** (Proposition 8 in [Wan19])

Ist  $\rho > 0$  und  $\Sigma_{\beta_t}$  eine endliche und positiv definite Matrix, dann gilt

$$\Sigma_{\beta_t} \Lambda_\rho \Sigma_{\beta_t} < \Sigma_{\beta_t}.$$

Die folgenden Theoreme 3 und 4 unterstellen jeweils, dass das logistische Regressionsmodell misspezifiziert ist und die wahre, den Daten unterliegende Verteilung ist:

$$\mathbf{P}(y = 1|x) = p_t(x),$$

$p_t(x)$  unbekannt.

**Eigenschaft ★.**  $\mathbf{E}[(p_t(x) - p(x, \beta_l))h(x)x] = 0$  ★

**Theorem 3.** (Theorem 24 in [Wan19])

Sei das pilot Sample unabhängig von  $\mathcal{D}_N$ ,  $\sqrt{n_0}(\hat{\beta}_0 - \beta_l) \rightsquigarrow \mathbb{N}(0, \Sigma_0)$  und Annahmen 1-3 gelten. Wenn  $n_0/N \rightarrow \rho_0$ ,  $n/N \rightarrow \rho$  mit  $\rho_0, \rho \in (0, 1)$ , dann ist für  $n_0, n, N \rightarrow \infty$  bedingt auf  $\mathcal{D}_N$

$$\sqrt{n}(\hat{\beta}_{ww} - \hat{\beta}_{wMLE}) \rightsquigarrow \mathbb{N}(0, \omega \kappa_a^{-1}),$$

wobei

$$\begin{aligned} \kappa_a &= \frac{1}{4} \mathbf{E}[(p_t(x) - 2p_t(x)p(x, \beta_l) + p(x, \beta_l))h(x)xx^T], \\ \omega &= \mathbf{E}[(p_t(x) - 2p_t(x)p(x, \beta_l) + p(x, \beta_l))h(x)]. \end{aligned}$$

$\hat{\beta}_{wMLE}$  erfüllt

$$\sqrt{N}(\hat{\beta}_{wMLE} - \beta_l) \rightsquigarrow \mathbb{N}(0, \kappa_a^{-1}(\kappa_b + \rho_0^{-1} \kappa_c \Sigma_0 \kappa_c) \kappa_a^{-1}),$$

wobei

$$\begin{aligned} \kappa_b &= \frac{1}{4} \mathbf{E}[(p_t(x) - 2p_t(x)p(x, \beta_l) + p^2(x, \beta_l))h^2(x)xx^T], \\ \kappa_c &= \frac{1}{4} \mathbf{E}[(1 - 2p(x, \beta_l))(p_t(x) - p(x, \beta_l))h(x)xx^T]. \end{aligned}$$

**Bemerkung.** Wir benötigen in Theorem 3 vermutlich zusätzlich  $\kappa_a$  positiv definit.

**Theorem 4.** (Theorem 26 in [Wan19])

Angenommen das pilot Sample ist unabhängig von  $\mathcal{D}_N$  und die pilot Estimators erfüllen  $\sqrt{n_0}(\hat{\beta}_0 - \beta_l) \rightsquigarrow \mathbb{N}(0, \Sigma_0)$  und  $\hat{\Psi}_0 = \omega + o_P(1)$ . Unter Annahmen 1 und 2, wenn  $n_0/N \rightarrow \rho_0$  und  $n/N \rightarrow \rho$  mit  $\rho_0, \rho \in (0, 1)$  ist bedingt auf  $\mathcal{D}_N$  für  $n_0, n, N \rightarrow \infty$

$$\sqrt{n}(\hat{\beta}_p - \hat{\beta}_{wMLE}) \rightsquigarrow \mathbb{N}(0, \omega \kappa_a^{-1} \kappa_d \kappa_a^{-1}),$$

wobei  $\kappa_d = \frac{1}{4} \mathbf{E}[|\psi(\beta_l)|(1 - \rho\omega^{-1}|\psi(\beta_l)|h(x))_+ h(x)xx^T]$ .

**Theorem 5.** (Theorem 18 in [Wan19])

Sei das logistische Regressionsmodell korrekt spezifiziert und der pilot Estimator  $\hat{\beta}_0$  (der unabhängig von  $\mathcal{D}_N$  ist) inkonsistent, d.h.  $\hat{\beta}_0 = \beta_0 + o_P(1)$ ,  $\beta_t \neq \beta_0$ . Dann folgt unter Annahme 1-3, bedingt auf  $\mathcal{D}_N$  für  $n, N \rightarrow \infty$

$$\sqrt{n}(\hat{\beta}_{uw} - \hat{\beta}_{wMLE}) \rightsquigarrow \mathbb{N}(0, \Psi(\beta_0)\varsigma_a^{-1}).$$

Ist  $n/N \rightarrow 0$ , dann

$$\sqrt{n}(\hat{\beta}_{uw} - \beta_t) \rightsquigarrow \mathbb{N}(0, \Psi(\beta_0)\varsigma_a^{-1}),$$

wobei hier  $\hat{\beta}_{wMLE}$

$$\sqrt{N}(\hat{\beta}_{wMLE} - \beta_t) \rightsquigarrow \mathbb{N}(0, \varsigma_a^{-1} \varsigma_b \varsigma_a^{-1})$$

erfüllt.

**Theorem 6.** (Theorem 21 in [Wan19])

Sei das logistische Regressionsmodell korrekt spezifiziert und die pilot Estimators unabhängig von  $\mathcal{D}_N$  und inkonsistent, d.h.,  $\hat{\beta}_0 = \beta_0 + o_P(1)$ ,  $\beta_t \neq \beta_0$  und  $\hat{\Psi}_0 = \Psi_0 + o_P(1)$ ,  $\Psi(\beta_t) \neq \Psi_0$ . Es folgt unter Annahme 1 und 2, bedingt auf  $\mathcal{D}_N$ , dass für  $n, N \rightarrow \infty$ , mit  $n/N \rightarrow 0$  gilt

$$\sqrt{n}(\hat{\beta}_p - \beta_t) \rightsquigarrow \mathbb{N}(0, \Psi_0 \varsigma_a^{-1}).$$

Ist  $n/N \rightarrow \rho$ , dann

$$\sqrt{n}(\hat{\beta}_p - \hat{\beta}_{wMLE}) \rightsquigarrow \mathbb{N}(0, \Psi_0 \varsigma_a^{-1} \varsigma_c \varsigma_a^{-1}).$$

### 3 Beweis von Lemma 4

Wir beginnen mit der folgenden Zerlegung,

$$\begin{aligned}
& \frac{1}{n} \sum_{i=1}^n \phi_i^*(\beta_t - \hat{\beta}_0 + s_n) x_i^* x_i^{*T} \\
&= \frac{1}{n} \sum_{i=1}^n \phi_i^*(\beta_t - \hat{\beta}_0 + s_n) x_i^* x_i^{*T} I(\|x_i^*\|^2 \leq n) + \frac{1}{n} \sum_{i=1}^n \phi_i^*(\beta_t - \hat{\beta}_0 + s_n) x_i^* x_i^{*T} I(\|x_i^*\|^2 > n) \\
&\equiv \Delta_1 + \Delta_2
\end{aligned}$$

$\Delta_2$  ist  $o_P(1) \Leftrightarrow \|\Delta_2\|$  ist  $o_P(1)$ . Es gilt jedoch  $\|\Delta_2\| \leq \frac{1}{n} \sum_{i=1}^n \phi_i^*(\beta_t - \hat{\beta}_0 + s_n) \|x_i^*\|^2 I(\|x_i^*\|^2 > n) = o_P(1)$  (siehe Seite 36 in [Wan19]) und damit  $\|\Delta_2\| = o_P(1)$ . Bemerke insbesondere  $\|xx^T\| = \sqrt{\sum_{i,j=1}^d |x_i x_j|^2} = \sum_{i=1}^d x_i^2 = \|x\|^2$ .

Weiter gilt

$$\begin{aligned}
& \left\| \mathbf{E}[\Delta_1 | \mathcal{D}_N, \hat{\beta}_0] - \sum_{i=1}^N \pi_i(\hat{\beta}_0) \phi_i(\beta_t - \hat{\beta}_0) x_i x_i^T \right\| \\
&= \left\| \sum_{i=1}^N \pi_i(\hat{\beta}_0) \phi_i(\beta_t - \hat{\beta}_0 + s_n) x_i x_i^T I(\|x_i\|^2 \leq n) - \sum_{i=1}^N \pi_i(\hat{\beta}_0) \phi_i(\beta_t - \hat{\beta}_0) x_i x_i^T \right\| \\
&= \left\| \sum_{i=1}^N \pi_i(\hat{\beta}_0) x_i x_i^T (\phi_i(\beta_t - \hat{\beta}_0 + s_n) - \phi_i(\beta_t - \hat{\beta}_0)) - \sum_{i=1}^N \pi_i(\hat{\beta}_0) \phi_i(\beta_t - \hat{\beta}_0 + s_n) x_i x_i^T I(\|x_i\|^2 > n) \right\| \\
&\leq \sum_{i=1}^N \pi_i(\hat{\beta}_0) \|x_i\|^2 o_P(1) + \sum_{i=1}^N \pi_i(\hat{\beta}_0) \phi_i(\beta_t - \hat{\beta}_0 + s_n) \|x_i\|^2 I(\|x_i\|^2 > n) \\
&\leq \frac{\frac{1}{N} \sum_{i=1}^N |\psi_i(\hat{\beta}_0)| h(x_i) \|x_i\|^2 o_P(1)}{\Psi_N(\hat{\beta}_0)} + o_P(1) \\
&\leq \frac{\frac{1}{N} \sum_{i=1}^N h(x_i) \|x_i\|^2 o_P(1)}{\Psi_N(\hat{\beta}_0)} + o_P(1) \\
&= o_P(1),
\end{aligned}$$

wobei für den letzten Schritt Lemma 1 mit  $\phi_i(\beta_t - \hat{\beta}_0 + s_n) - \phi_i(\beta_t - \hat{\beta}_0) = o_P(1)$  und betragsmäßig durch 1 beschränkt, sowie das schwache Gesetz der großen Zahlen genutzt wurde.  $\star$  siehe S.36 in [Wan19].

Damit müssen wir nur noch zeigen, dass  $\Delta_1 - \mathbf{E}[\Delta_1 | \mathcal{D}_N, \hat{\beta}_0] = o_P(1) \Leftrightarrow \|\Delta_1 - \mathbf{E}[\Delta_1 | \mathcal{D}_N, \hat{\beta}_0]\| = o_P(1)$ . Hierzu folgender Trick:

$$\begin{aligned}
\|\Delta_1 - \mathbf{E}[\Delta_1 | \mathcal{D}_N, \hat{\beta}_0]\| &= \sqrt{\sum_{k,j=1}^d |\Delta_{1kj} - \mathbf{E}[\Delta_{1kj} | \mathcal{D}_N, \hat{\beta}_0]|^2} \leq \sqrt{\left( \sum_{k,j=1}^d |\Delta_{1kj} - \mathbf{E}[\Delta_{1kj} | \mathcal{D}_N, \hat{\beta}_0]| \right)^2} \\
&= \sum_{k,j=1}^d |\Delta_{1kj} - \mathbf{E}[\Delta_{1kj} | \mathcal{D}_N, \hat{\beta}_0]|
\end{aligned}$$

und es reicht zu zeigen, dass  $\Delta_{1kj} - \mathbf{E}[\Delta_{1kj} | \mathcal{D}_N, \hat{\beta}_0] = o_P(1) \forall k, j$ . Dafür zeigen wir, dass die bedingte Varianz  $\mathbf{V}[\Delta_{1kj} | \mathcal{D}_N, \hat{\beta}_0] = \mathbf{E}[(\Delta_{1kj} - \mathbf{E}[\Delta_{1kj} | \mathcal{D}_N, \hat{\beta}_0])^2 | \mathcal{D}_N, \hat{\beta}_0]$  stochastisch

gegen 0 konvergiert.

$$\begin{aligned}
\mathbf{V}[\Delta_{1kj}|\mathcal{D}_N, \hat{\beta}_0] &= \mathbf{V} \left[ \frac{1}{n} \sum_{i=1}^n \phi_i^*(\beta_t - \hat{\beta}_0 + s_n)(x_i^*)_k(x_i^*)_j I(\|x_i^*\|^2 \leq n) | \mathcal{D}_N, \hat{\beta}_0 \right] \\
&\stackrel{iid}{=} \frac{1}{n} \mathbf{V} \left[ \phi^*(\beta_t - \hat{\beta}_0 + s_n)(x^*)_k(x^*)_j I(\|x^*\|^2 \leq n) | \mathcal{D}_N, \hat{\beta}_0 \right] \\
&\leq \frac{1}{n} \mathbf{E} \left[ \phi^*(\beta_t - \hat{\beta}_0 + s_n)^2 ((x^*)_k(x^*)_j)^2 I(\|x^*\|^2 \leq n) | \mathcal{D}_N, \hat{\beta}_0 \right] \\
&\leq \frac{1}{16n} \mathbf{E} \left[ \sum_{k,j=1}^d ((x^*)_k(x^*)_j)^2 I(\|x^*\|^2 \leq n) | \mathcal{D}_N, \hat{\beta}_0 \right] \\
&= \frac{1}{16n} \mathbf{E} \left[ \|x^*\|^4 I(\|x^*\|^2 \leq n) | \mathcal{D}_N, \hat{\beta}_0 \right] \\
&\quad \vdots \quad (\text{siehe S.36, [Wan19]}) \\
&\leq \frac{1}{16n} \left( 1 + \sum_{i=1}^{n-1} 3i \mathbf{P}(\|x^*\|^2 > i | \mathcal{D}_N, \hat{\beta}_0) \right) = o_P(1),
\end{aligned}$$

wobei die letzte Gleichheit aus [Wan19], S.37 folgt. Bemerke, dass eigentlich richtig ist  $\frac{1}{n} \sum_{i=1}^n i \mathbf{P}(\|x^*\|^2 > i | \mathcal{D}_N, \hat{\beta}_0) = \frac{1}{n} \sum_{i=1}^n i \sum_{j=1}^N \pi_j(\hat{\beta}_0) I(\|x_j\|^2 > i)$ .

## 4 Symbolübersicht

$\beta_t =$  wahrer Parametervektor (das “ = “ ist als ‘ist gleich’

zu lesen, im Folgenden nicht mehr angemerkt)

$$\hat{\beta}_{\text{MLE}} = \arg \max_{\beta} \sum_{i=1}^N \{y_i x_i^T \beta - \log(1 + e^{\beta^T x_i})\}$$

$$\hat{\beta}_w^{\pi} = \arg \max_{\beta} \sum_{i=1}^n \frac{y_i^* \beta^T x_i^* - \log(1 + e^{\beta^T x_i^*})}{\pi_i^*}$$

$$\hat{\beta}_w = \arg \max_{\beta} \sum_{i=1}^n \frac{y_i^* \beta^T x_i^* - \log(1 + e^{\beta^T x_i^*})}{\pi_i^{\text{OS}}(\hat{\beta}_0)^*}$$

$\hat{\beta}_0 =$  (konsistenter) pilot Estimator von  $\beta_t$ , Achtung! bei Theorem 3-6 siehe  $\beta_l$  und  $\beta_0$

$$\tilde{\beta}_{uw} = \arg \max_{\beta} \sum_{i=1}^n (\beta^T x_i^* y_i^* - \log(1 + e^{\beta^T x_i^*}))$$

$$\hat{\beta}_{uw} = \tilde{\beta}_{uw} + \hat{\beta}_0$$

$$\hat{\beta}_{\text{wMLE}} = \arg \max_{\beta} \sum_{i=1}^N |y_i - p(x_i, \hat{\beta}_0)| h(x_i) [y_i x_i^T (\beta - \hat{\beta}_0) - \log(1 + e^{x_i^T (\beta - \hat{\beta}_0)})]$$

$$\tilde{\beta}_p = \arg \max_{\beta} \sum_{i=1}^{n^*} (n \pi_i^*(\hat{\beta}_0) \vee 1) (\beta^T x_i^* y_i^* + \log(1 + e^{\beta^T x_i^*}))$$

$$\hat{\beta}_p = \tilde{\beta}_p + \hat{\beta}_0$$

$\beta_l =$  Minimierer von  $\mathbf{E}[-p_t(x)h(x)x^T \beta + h(x) \log(1 + e^{\beta^T x})]$ ,  $\hat{\beta} - \beta_l = o_P(1)$  (Theorem 3 und 4)

$\beta_0 : \beta_0 = \hat{\beta}_0 + o_P(1)$  (Theorem 5 und 6)

$$\delta_i^{\hat{\beta}_0} = I(u_i \leq n \pi_i^p(\hat{\beta}_0))$$

$$\mathcal{D}_N = ((x_1, y_1), \dots, (x_N, y_N))$$

$$\eta_i = |\psi_i(\hat{\beta}_0)| \psi_i(\beta_t - \hat{\beta}_0) h(x_i) x_i$$

$$\eta_i = |\psi_i(\hat{\beta}_0)| \psi_i(\beta_l - \hat{\beta}_0) h(x_i) x_i \text{ (Theorem 3 und 4)}$$

$$\kappa_a = \frac{1}{4} \mathbf{E}[(p_t(x) - 2p_t(x)p(x, \beta_l) + p(x, \beta_l))h(x)xx^T]$$

$$\kappa_b = \frac{1}{4} \mathbf{E}[(p_t(x) - 2p_t(x)p(x, \beta_l) + p^2(x, \beta_l))h^2(x)xx^T]$$

$$\kappa_c = \frac{1}{4} \mathbf{E}[(1 - 2p(x, \beta_l))(p_t(x) - p(x, \beta_l))h(x)xx^T]$$

$$\kappa_d = \frac{1}{4} \mathbf{E} [|\psi(\beta_l)|(1 - \rho \omega^{-1} |\psi(\beta_l)| h(x))_+ h(x)xx^T]$$

$$\dot{\lambda}_{uw}^*(\beta_t) = \sum_{i=1}^n (y_i^* - p_i^*(\beta_t - \hat{\beta}_0)) x_i^*$$

$$\lambda_p(\beta) = \sum_{i=1}^N \delta_i^{\hat{\beta}_0} (n \pi_i^p(\hat{\beta}_0) \vee 1) ((\beta - \hat{\beta}_0)^T x_i y_i - \log(1 + e^{(\beta - \hat{\beta}_0)^T x_i}))$$

$$\dot{\lambda}_p(\beta) = \sum_{i=1}^N \delta_i^{\hat{\beta}_0} (n \pi_i^p(\hat{\beta}_0) \vee 1) (y_i - p(x_i, \beta - \hat{\beta}_0)) x_i$$

$$\Lambda_\rho = \frac{\mathbf{E}[|\psi(\beta_t)|h(x)(\Psi(\beta_t) - \rho|\psi(\beta_t)|h(x))_+xx^T]}{4\Psi^2(\beta_t)}$$

$$\Lambda_u = \frac{\mathbf{E}[|\psi(\beta_t)|(\rho|\psi(\beta_t)|h(x) \vee \Psi(\beta_t))h(x)xx^T]}{4\Psi^2(\beta_t)}$$

$$M_N = \frac{1}{N} \sum_{i=1}^N \phi_i(\hat{\beta}_{\text{MLE}})x_i x_i^T$$

$$M = \mathbf{E}[\phi(\beta_t)xx^T]$$

$n_0$ : Größe des Pilot-Subsamples

$n$ : Größe des Second-Stage-Subsamples (Ziehen mit Zurücklegen)

$n^*$ : Größe des Second-Stage-Subsamples (Poisson Subsampling) (zufällig)

$$p(x, \beta) = \frac{e^{x^T \beta}}{1 + e^{x^T \beta}}$$

$$p_t(x) = \mathbf{P}(y = 1|x) \text{ (Theorem 3 und 4)}$$

$$\pi_i^{\text{OS}}(\beta) = \frac{|y_i - p(x_i, \beta)|h(x_i)}{\sum_{j=1}^N |y_j - p(x_j, \beta)|h(x_j)}$$

$$\pi_i^p(\hat{\beta}_0) = \frac{|y_i - p(x_i, \hat{\beta}_0)|h(x_i)}{N \hat{\Psi}_0} \text{ oder auch einfach nur } \pi_i^p$$

$$\rho = \lim_{n, N \rightarrow \infty} n/N \text{ (an manchen Stellen)}$$

$$\rho_0 = \text{Grenzwert von } n_0/N \text{ (an manchen Stellen)}$$

$$s_a = \mathbf{E}[(1 - p(x, \beta_t))p(x, \beta_0)p(x, \beta_t - \beta_0)h(x)xx^T]$$

$$s_b = \mathbf{E}[\phi(\beta_0)\phi(\beta_t - \beta_0)h^2(x)xx^T]$$

$$s_c = \mathbf{E}\left[|\psi(\beta_0)|(1 - \rho\Psi_0^{-1}|\psi(\beta_0)|h(x))_+\psi^2(\beta_t - \beta_0)h(x)xx^T\right]$$

$$\Sigma_\beta = \left[ \frac{\mathbf{E}[\phi(\beta)h(x)xx^T]}{4\Phi(\beta)} \right]^{-1}$$

$$\Sigma_{\text{wMLE}} = \left[ \mathbf{E}[\phi(\beta_t)h(x)xx^T] \right]^{-1} \mathbf{E}[\phi(\beta_t)h^2(x)xx^T] \left[ \mathbf{E}[\phi(\beta_t)h(x)xx^T] \right]^{-1}$$

$\Sigma_0$ : asymptotische Kovarianzmatrix von  $\sqrt{n_0}(\hat{\beta}_0 - \beta_l)$

$$V_N^{\text{OS}} = M_N^{-1}V_{N_c}^{\text{OS}}M_N^{-1}$$

$$V_{N_c}^{\text{OS}} = \left( \frac{1}{N} \sum_{i=1}^N |y_i - p(x_i, \hat{\beta}_{\text{MLE}})|h(x_i) \right) \left( \frac{1}{N} \sum_{i=1}^N \frac{|y_i - p(x_i, \hat{\beta}_{\text{MLE}})|x_i x_i^T}{h(x_i)} \right)$$

$$V_c^{\text{OS}} = M^{-1}V_c^{\text{OS}}M^{-1}$$

$$V_c^{\text{OS}} = 4\Phi(\beta_t)\mathbf{E}\left[ \frac{\phi(\beta_t)xx^T}{h(x)} \right]$$

$$\phi(\beta) = p(x, \beta)(1 - p(x, \beta)), \quad \phi_i(\beta) = p(x_i, \beta)(1 - p(x_i, \beta))$$

$$\Phi(\beta) = \mathbf{E}[\phi(\beta)h(x)]$$

$$\psi(\beta) = y - p(x, \beta), \quad \psi_i(\beta) = y_i - p(x_i, \beta)$$

$$\Psi_N(\beta) = \frac{1}{N} \sum_{i=1}^N |y_i - p(x_i, \beta)| h(x_i)$$

$$\Psi(\beta) = \mathbf{E}[|y - p(x, \beta)| h(x)]$$

$$\hat{\Psi}_0 : \text{pilot Estimator von } \Psi(\beta_t)$$

$$\Psi_0 : \Psi_0 = \hat{\Psi}_0 + o_P(1) \text{ (Theorem 5 und 6)}$$

$$\omega = \mathbf{E}[(p_t(x) - 2p_t(x)p(x, \beta_l) + p(x, \beta_l))h(x)]$$

$$\text{Relative Efficiency} = \frac{MSE(\check{\beta}_w)}{MSE(\check{\beta}_{new})}$$

$$MSE(\check{\beta}) = \frac{1}{S} \sum_{s=1}^S \|\check{\beta}^{(s)} - \beta_t\|^2$$

## Literatur

- [CH10] Guang Cheng und Jianhua Z. Huang. “Bootstrap consistency for general semi-parametric  $M$ -estimation”. English. In: *The Annals of Statistics* 38.5 (2010), S. 2884–2915. ISSN: 0090-5364; 2168-8966/e.
- [FH14] William Fithian und Trevor Hastie. “Local case-control sampling: efficient subsampling in imbalanced data sets”. English. In: *The Annals of Statistics* 42.5 (2014), S. 1693–1724. ISSN: 0090-5364; 2168-8966/e.
- [HP11] Nils Lid Hjort und David Pollard. “Asymptotics for minimisers of convex processes”. In: (19. Juli 2011). arXiv: 1107.3806v1 [math.ST].
- [Mus88] Dieter Mussmann. “Sufficiency and Jensen’s inequality for conditional expectations”. English. In: *Annals of the Institute of Statistical Mathematics* 40.4 (1988), S. 715–726. ISSN: 0020-3157; 1572-9052/e.
- [Ser02] Robert J. Serfling. *Approximation theorems of mathematical statistics*. English. New York, NY: Wiley, 2002, S. 371. ISBN: 0-471-21927-4/pbk.
- [van98] A. W. van der Vaart. *Asymptotic statistics*. Bd. 3. Cambridge Series in Statistical and Probabilistic Mathematics. Cambridge University Press, Cambridge, 1998, S. xvi+443. ISBN: 0-521-49603-9; 0-521-78450-6. DOI: 10.1017/CB09780511802256.
- [Wan19] HaiYing Wang. “More Efficient Estimation for Logistic Regression with Optimal Subsamples”. In: *J. Mach. Learn. Res.* 20 (2019), 132:1–132:59. URL: <http://jmlr.org/papers/v20/18-596.html>.
- [WZM18] HaiYing Wang, Rong Zhu und Ping Ma. “Optimal subsampling for large sample logistic regression”. English. In: *Journal of the American Statistical Association* 113.522 (2018), S. 829–844. ISSN: 0162-1459; 1537-274X/e.
- [XL08] Shifeng Xiong und Guoying Li. “Some results on the convergence of conditional distributions”. English. In: *Statistics & Probability Letters* 78.18 (2008), S. 3249–3253. ISSN: 0167-7152.

Die Quellen [CH10], [FH14], [WZM18], [XL08] als zusätzliche Vortragsliteratur.