

1.3 Wiederholung der Konvergenzkonzepte

Wir erlauben nun, dass der Stichprobenumfang n unendlich groß wird und untersuchen das Verhalten von Stichprobengrößen für diesen Fall. Dies liefert uns nützliche Approximationen für den endlichen Fall. Wir betrachten jetzt 3 Typen von Konvergenz. Speziell wird \bar{X}_n , das Mittel von n Beobachtungen, untersucht.

1.3.1 Konvergenz in Wahrscheinlichkeit

Definition 1.3.1: Eine Folge von Zufallsvariablen X_1, X_2, \dots **konvergiert in Wahrscheinlichkeit** gegen eine Zufallsvariable X , falls für jedes $\epsilon > 0$ gilt

$$\lim_{n \rightarrow \infty} P(|X_n - X| \geq \epsilon) = 0,$$

was äquivalent ist mit

$$\lim_{n \rightarrow \infty} P(|X_n - X| < \epsilon) = 1.$$

Wir schreiben dafür $X_n \xrightarrow{P} X$.

Hierbei sind die X_1, X_2, \dots nicht notwendigerweise iid Variablen.

Statistiker beschäftigen sich häufig mit Situationen in denen die Grenzvariable eine Konstante und die Zufallsvariablen in der Folge das Stichprobenmittel ist.

Satz 1.3.1: (Schwaches Gesetz der großen Zahlen – WLLN) Seien X_1, X_2, \dots iid Zufallsvariablen mit $E(X_i) = \mu$ und $\text{var}(X_i) = \sigma^2 < \infty$. Dann gilt für jedes $\epsilon > 0$

$$\lim_{n \rightarrow \infty} P(|\bar{X}_n - \mu| < \epsilon) = 1,$$

also konvergiert das Stichprobenmittel \bar{X}_n in Wahrscheinlichkeit gegen das Populationsmittel μ , d.h. $\bar{X}_n \xrightarrow{P} \mu$.

Das WLLN sagt aus, dass sich unter recht allgemeinen Bedingungen das Stichprobenmittel dem Populationsmittel nähert falls $n \rightarrow \infty$.

Diese Eigenschaft, dass sich eine Folge der gleichen Stichprobengröße für $n \rightarrow \infty$ einer Konstanten nähert, nennt man auch **Konsistenz**.

Zentrale Bedeutung hat im Folgenden auch die **Chebychev'sche Ungleichung**.
Zur Erinnerung gilt für jedes beliebige $\epsilon > 0$

$$P(|X - a| \geq \epsilon) \leq \frac{1}{\epsilon^2} \mathbf{E}(X - a)^2$$

und speziell, dass

$$P(|X - \mathbf{E}(X)| \geq \epsilon) \leq \frac{1}{\epsilon^2} \text{var}(X).$$

Damit kann recht einfach der Satz 1.3.1 bewiesen werden.

Beispiel 1.3.1: Sei X_1, X_2, \dots eine Folge von iid Variablen mit $E(X_i) = \mu$ und $\text{var}(X_i) = \sigma^2 < \infty$. Hält das WLLN auch für

$$S_n^2 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X}_n)^2$$

Chebychev sagt aus, dass

$$P(|S_n^2 - \sigma^2| \geq \epsilon) \leq \frac{1}{\epsilon^2} \text{var}(S_n^2).$$

Somit ist $\text{var}(S_n^2) \rightarrow 0$ für $n \rightarrow \infty$ eine hinreichende Bedingung dafür, dass S_n^2 in Wahrscheinlichkeit gegen σ^2 konvergiert.

Eine natürliche Erweiterung von Definition 1.3.1 bezieht sich auf Funktionen von Zufallsvariablen. Wir wollen der Frage nachgehen, ob bei Konvergenz in Wahrscheinlichkeit der Folge X_1, X_2, \dots gegen X oder gegen a , auch die Folge $h(X_1), h(X_2), \dots$ konvergiert.

Satz 1.3.2: Angenommen die Folge von Zufallsvariablen X_1, X_2, \dots konvergiert in Wahrscheinlichkeit gegen eine Zufallsvariable X , und sei h eine stetige Funktion. Dann konvergiert $h(X_1), h(X_2), \dots$ in Wahrscheinlichkeit gegen $h(X)$.

Beispiel 1.3.1 Fortsetzung: Falls die Stichprobenvarianz S_n^2 konsistent ist für σ^2 , dann ist somit auch die Stichprobenstandardabweichung

$$S_n = \sqrt{S_n^2} = h(S_n^2)$$

konsistent für σ .

Bemerke jedoch, dass S_n verzerrt ist für σ . Diese Verzerrung verschwindet aber asymptotisch.

1.3.2 Fast sichere Konvergenz

Dieses Konzept ist stärker als die Konvergenz in Wahrscheinlichkeit.

Manchmal bezeichnet man es auch als *Konvergenz mit Wahrscheinlichkeit 1*.

Es ist ähnlich zur punktweisen Konvergenz einer Funktionenfolge: überall bis auf einer Ausnahmemenge (mit Wahrscheinlichkeit 0, **almost sure**, a.s.).

Definition 1.3.2: Eine Folge von Zufallsvariablen X_1, X_2, \dots **konvergiert fast sicher** gegen eine Zufallsvariable X , falls für jedes $\epsilon > 0$ gilt

$$P \left(\lim_{n \rightarrow \infty} |X_n - X| < \epsilon \right) = 1.$$

Wir schreiben dafür $X_n \xrightarrow{f.s.} X$.

Eine Zufallsvariable ist eine reellwertige Funktion definiert auf einem Stichprobenraum S . Falls die Elemente in S mit s bezeichnet sind, dann sind $X_n(s)$ und $X(s)$ Funktionen die auch auf S definiert sind.

$X_n(s)$ konvergiert fast sicher gegen $X(s)$, für alle $s \in S$, ausgenommen vielleicht für $s \in N$, mit $N \subset S$ und $P(N) = 0$.

Beispiel 1.3.2: Sei S das abgeschlossene Intervall $[0, 1]$ mit der Gleichverteilung darauf definiert. Sei $X_n(s) = s + s^n$ und $X(s) = s$.

Für jedes $s \in [0, 1)$ gilt $s^n \rightarrow 0$ für $n \rightarrow \infty$ und $X_n(s) \rightarrow s = X(s)$.

Jedoch ist $X_n(1) = 2$ für alle n , sodass $X_n(1) \not\rightarrow 1 = X(1)$.

Aber Konvergenz tritt ein auf dem Bereich $[0, 1)$ und $P([0, 1)) = 1$. Damit konvergiert X_n gegen X fast sicher.

Fast sichere Konvergenz impliziert die Konvergenz in Wahrscheinlichkeit.

Das Starke Gesetz der großen Zahlen (SLLN) beschreibt die fast sichere Konvergenz zu einer Konstanten.

Satz 1.3.3: (Starkes Gesetz der großen Zahlen – SLLN) Seien X_1, X_2, \dots iid Zufallsvariablen mit $E(X_i) = \mu$ und $\text{var}(X_i) = \sigma^2 < \infty$. Dann gilt für jedes $\epsilon > 0$

$$P \left(\lim_{n \rightarrow \infty} |\bar{X}_n - \mu| < \epsilon \right) = 1,$$

also konvergiert das Stichprobenmittel \bar{X}_n fast sicher gegen das Populationsmittel μ , d.h. $\bar{X}_n \xrightarrow{f.s.} \mu$.

1.3.3 Konvergenz in Verteilung

Definition 1.3.3: Eine Folge von Zufallsvariablen X_1, X_2, \dots **konvergiert in Verteilung** gegen eine Zufallsvariable X , falls

$$\lim_{n \rightarrow \infty} F_{X_n} = F_X$$

in allen Punkten x , in denen $F_X(x)$ stetig ist. Wir schreiben dafür $X_n \xrightarrow{D} X$.

Hierbei konvergieren eigentlich die Verteilungsfunktionen (und nicht die Zufallsvariablen)!

Was ist eigentlich die Grenzverteilung von \bar{X}_n ?

Satz 1.3.4: Falls die Folge von Zufallsvariablen X_1, X_2, \dots in Wahrscheinlichkeit gegen die Zufallsvariable X konvergiert, dann konvergiert diese Folge auch in Verteilung gegen X .

Satz 1.3.5: Die Folge von Zufallsvariablen X_1, X_2, \dots , konvergiert in Wahrscheinlichkeit gegen eine Konstante μ , dann und nur dann, wenn diese Folge auch in Verteilung gegen μ konvergiert. Die Aussage

$$P(|X_n - \mu| > \epsilon) \rightarrow 0 \quad \text{für jedes } \epsilon > 0$$

ist daher äquivalent mit

$$P(X_n < x) \rightarrow \begin{cases} 0, & \text{falls } x < \mu, \\ 1, & \text{falls } x > \mu. \end{cases}$$

Satz 1.3.6: (Zentraler Grenzwertsatz – CLT) Seien X_1, X_2, \dots iid Zufallsvariablen mit $E(X_i) = \mu$ und $\text{var}(X_i) = \sigma^2 < \infty$. Bezeichne $G_n(x)$ die Verteilungsfunktion von $\sqrt{n}(\bar{X}_n - \mu)/\sigma$. Dann gilt für jedes $x \in \mathbb{R}$

$$\lim_{n \rightarrow \infty} G_n(x) = \int_{-\infty}^x \frac{1}{\sqrt{2\pi}} e^{-y^2/2} dy.$$

Also hat $\sqrt{n}(\bar{X}_n - \mu)/\sigma$ als Grenzverteilung die Standard-Normalverteilung.

Bemerkungen:

Wir beginnen eigentlich ohne Annahmen (bis auf Unabhängigkeit und endliche Varianzen) und enden in der Normalverteilung.

Diese Normalität stammt von den Summen von *kleinen* (endliche Varianzen) Störtermen.

Einschränkung: Keine Kenntnis wie gut diese Approximation ist!

Beispiel 1.3.3: Sei X_1, \dots, X_n eine Zufallsstichprobe aus einer Negativ-Binomial Verteilung für die gilt

$$P(X_1 = x|r, p) = \binom{r+x-1}{x} p^r (1-p)^x, \quad x = 0, 1, \dots$$

mit

$$E(X_1) = \frac{r(1-p)}{p}, \quad \text{var}(X_1) = \frac{r(1-p)}{p^2}.$$

Das CLT sagt aus, dass

$$\sqrt{n} \frac{\overline{X_n} - \frac{r(1-p)}{p}}{\sqrt{\frac{r(1-p)}{p^2}}}$$

asymptotisch $N(0, 1)$ verteilt ist.

Weiters gilt die Faltungseigenschaft $\sum_{i=1}^n X_i \sim \text{Negativ-Binomial}(nr, p)$.

Wir betrachten die Situation: $r = 10$, $p = 1/2$ und $n = 30$.

Exakt: Damit ergibt sich exakt

$$P(\bar{X}_{30} \leq 11) = P\left(\sum_{i=1}^{30} X_i \leq 330\right) = \sum_{x=0}^{330} \binom{300+x-1}{x} \left(\frac{1}{2}\right)^{300} \left(\frac{1}{2}\right)^x = 0.8916.$$

Diesem Ergebnis liegt eine ziemlich komplexe Berechnung zugrunde.

Approximativ: Das CLT liefert mit $E(\bar{X}_{30}) = r = 10$ und $\text{var}(\bar{X}_{30}) = 2r/n = 20/n$ die Approximation

$$P(\bar{X}_{30} \leq 11) = P\left(\sqrt{30} \frac{\bar{X}_{30} - 10}{\sqrt{20}} \leq \sqrt{30} \frac{11 - 10}{\sqrt{20}}\right) \approx P(Z \leq \sqrt{3/2}) = 0.88966,$$

wobei $Z \sim N(0, 1)$.

Ein Approximationswerkzeug, das häufig zusammen mit dem CLT verwendet wird, ist der folgende Satz:

Satz 1.3.7: (Satz von Slutsky) Falls $X_n \xrightarrow{D} X$ und $Y_n \xrightarrow{P} a$, mit einer Konstanten a , dann gilt

(a) $Y_n X_n \xrightarrow{D} aX$,

(b) $Y_n + X_n \xrightarrow{D} a + X$.

Beispiel 1.3.4: Angenommen

$$\sqrt{n} \frac{\bar{X}_n - \mu}{\sigma} \xrightarrow{D} N(0, 1)$$

aber σ^2 sei unbekannt. Aus Beispiel 1.3.1 wissen wir, dass $S_n^2 \xrightarrow{P} \sigma^2$ falls $\lim_{n \rightarrow \infty} \text{var}(S_n^2) = 0$.

Für stetige Transformationen $g(\cdot)$ liefert Satz 1.3.2: $X_n \xrightarrow{P} X \Rightarrow g(X_n) \xrightarrow{P} g(X)$.

Hier: $S_n^2 \xrightarrow{P} \sigma^2 \Rightarrow \sqrt{S_n^2} \xrightarrow{P} \sqrt{\sigma^2}$ und $S_n^2 \xrightarrow{P} \sigma^2 \Rightarrow 1/S_n \xrightarrow{P} 1/\sigma$.

Also gilt auch $\sigma/S_n \xrightarrow{P} 1$. Mittels Slutsky (Satz 1.3.7) folgt damit:

$$\underbrace{\sqrt{n} \frac{\bar{X}_n - \mu}{\sigma}}_{\xrightarrow{D} N(0,1)} \cdot \underbrace{\frac{\sigma}{S_n}}_{\xrightarrow{P} 1} = \sqrt{n} \frac{\bar{X}_n - \mu}{S_n} \xrightarrow{D} N(0, 1).$$

Satz 1.3.8: (Delta Methode) Sei Y_n eine Folge von Zufallsvariablen die

$$\sqrt{n}(Y_n - \theta) \xrightarrow{D} N(0, \sigma^2)$$

genügt. Sei g eine reellwertige Funktion mit $g'(\theta) \neq 0$. Dann gilt

$$\sqrt{n}\left(g(Y_n) - g(\theta)\right) \xrightarrow{D} N\left(0, \sigma^2[g'(\theta)]^2\right).$$

Satz 1.3.9: (Delta Methode 2. Ordnung) Sei Y_n eine Folge von Zufallsvariablen die

$$\sqrt{n}(Y_n - \theta) \xrightarrow{D} N(0, \sigma^2)$$

genügt. Für eine Funktion g und für den Wert θ sei $g'(\theta) = 0$ und es existiere $g''(\theta) \neq 0$. Dann gilt

$$n\left(g(Y_n) - g(\theta)\right) \xrightarrow{D} \sigma^2 \frac{g''(\theta)}{2} \chi_1^2.$$