

K 16 Verteilungen für die Statistik

Seien

$$X_1, \dots, X_n$$

Zufallsvariablen und

$$W_1, \dots, W_m$$

Statistiken, die aus $\{X_i\}$ berechnet sind. z.B.

$$W_1 = \frac{1}{n} \sum_{i=1}^n X_i$$

$$W_2 = \max\{X_1, \dots, X_n\}$$

$$W_3 = \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2$$

Jede W_j ist eine Transformation der $\{X_i\}$ und deshalb auch eine ZV. Wenn wir annehmen, dass die $\{X_i\}$ u.i.v. sind, können wir im Prinzip die Verteilungen von allen möglichen W_j ableiten.

Um Stichprobenwerte zu beurteilen, brauchen wir die Verteilungen der entsprechenden Statistiken.

Statistiken aus Stichproben

Sei X eine ZV mit Dichte f und Verteilungsfunktion F .

Seien $\{X_i; i = 1, \dots, n\}$ eine zufällige Stichprobe aus X .

$$\Rightarrow \{X_i\} \quad \text{u.i.v.}$$

Statistiken sind Zusammenfassungen der Daten aus der Stichprobe.

16.2 Resultate für alle Verteilungen

16.2.1 Verteilung von \bar{X}

Der ZGS besagt, dass für $n \rightarrow \infty$

$$\bar{X} \rightarrow N\left(\mu, \frac{\sigma^2}{n}\right)$$

unabhängig von der Form der Verteilung der $\{X_i\}$.

16.2.2 Verteilung von $\max X$

Für X_i mit Verteilungsfunktion $F(x)$ hat

$$Y = \max X$$

die Verteilungsfunktion

$$G(y) = F(y)^n$$

16.3 Die χ_k^2 Verteilung für X^2 und Quadratsummen

$$X \sim N(0, 1) \Rightarrow Y = X^2 \sim \chi_1^2$$

Seien $g(y)$ die Dichte von $Y = X^2$ und $G(y)$ die Verteilungsfunktion von Y .

$$\begin{aligned} G_Y(y) &= P(Y \leq y) \\ &= P(X^2 \leq y) \\ &= P(-\sqrt{y} \leq X \leq \sqrt{y}) \\ &= 1 - 2\Phi(-\sqrt{y}) \\ g(y) &= \frac{1}{\sqrt{y}} \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}y} \end{aligned}$$

eine χ_1^2 Dichte.

Die Chiquadratverteilung mit k Freiheitsgraden, χ_k^2 , hat die Dichte

$$f(x) = \frac{x^{\frac{k}{2}-1} e^{-\frac{x}{2}}}{\Gamma\left(\frac{k}{2}\right) 2^{\frac{k}{2}}}$$

mit Erwartungswert k und Varianz $2k$.

Die charakteristische Funktion für $Y \sim \chi_k^2$ ist

$$(1 - 2it)^{-\frac{k}{2}}$$

Für die Chiquadratverteilung gilt

wenn $Y_1 \sim \chi_{k_1}^2$ $Y_2 \sim \chi_{k_2}^2$ unabhängig

$$Y_1 + Y_2 \sim \chi_{k_1+k_2}^2$$

weil aus den c.f.'s folgt

$$(1 - 2it)^{-\frac{k_1}{2}} * (1 - 2it)^{-\frac{k_2}{2}} = (1 - 2it)^{-\frac{k_1+k_2}{2}}$$

16.3 Die Gammaverteilung

Eine gammaverteilte ZV $\Gamma(\lambda, \nu)$ hat die Dichte

$$f(y) = \frac{1}{\Gamma(\nu)} \lambda^\nu y^{\nu-1} e^{-\lambda y}$$

$$\Rightarrow \chi_1^2 \sim \Gamma\left(\frac{1}{2}, \frac{1}{2}\right) \quad \text{weil} \quad \Gamma\left(\frac{1}{2}\right) = \sqrt{\pi}$$

$$\chi_2^2 = \Gamma\left(\frac{1}{2}, 1\right) = E\left(\frac{1}{2}\right)$$

$$\chi_k^2 = \Gamma\left(\frac{1}{2}, \frac{k}{2}\right)$$

Der Erwartungswert und Varianz von $Y \sim \Gamma(\lambda, \nu)$ sind

$$E[Y] = \frac{\nu}{\lambda} \quad \text{und} \quad V[Y] = \frac{\nu}{\lambda^2}$$

Die charakteristische Funktion für $Y \sim \Gamma(\lambda, \nu)$ ist

$$\left(1 - \frac{it}{\lambda}\right)^{-\nu}$$

Die Gammaverteilung hat auch die wichtige Eigenschaft, dass

für $Y_1 \sim \Gamma(\lambda, \nu_1)$ $Y_2 \sim \Gamma(\lambda, \nu_2)$ unabhängig

$$Y_1 + Y_2 \sim \Gamma(\lambda, \nu_1 + \nu_2)$$

weil aus den c.f.'s folgt

$$\left(1 - \frac{it}{\lambda}\right)^{-\nu_1} * \left(1 - \frac{it}{\lambda}\right)^{-\nu_2} = \left(1 - \frac{it}{\lambda}\right)^{-\nu_1 - \nu_2}$$

16.4 Die Verteilung von s^2 für $X \sim N(0, 1)$

$$\sum_{i=1}^n X_i^2 \sim \chi_n^2$$

wenn alle $\{X_i\}$ u.i.v. $\sim N(0, 1)$, weil die Summe von zwei unabhängig χ^2 -verteilte ZV auch χ^2 -verteilt ist. Aber

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

ist NICHT die Summe von n unabhängig verteilten ZV.

Helmert hat die folgende orthogonale Transformation vorgeschlagen:

$$U_1 = \frac{1}{\sqrt{2}}(X_1 - X_2)$$

$$U_2 = \frac{1}{\sqrt{6}}(X_1 + X_2 - 2X_3)$$

⋮

$$U_{n-1} = \frac{1}{\sqrt{n(n-1)}}(X_1 + \dots + X_{n-1} - (n-1)X_n)$$

$$U_n = \frac{1}{\sqrt{n}} \sum X_i$$

Orthogonal heißt für $U_i = \sum_{j=1}^n c_{ij} X_j$ gilt $\sum_{i=1}^n c_{ij} c_{ik} = \delta_{jk}$

Die $\{U_i\}$ sind alle lineare Summen von u.i.v. Normal ZV, und deshalb sind sie auch normalverteilt:

$$E[U_i] = 0$$

$$V[U_i] = 1$$

$$E[U_i U_j] = 0 \quad i \neq j$$

$$\begin{aligned} \sum_{i=1}^n (X_i - \bar{X})^2 &= \sum_{i=1}^n X_i^2 - n\bar{X}^2 \\ &= \sum_{i=1}^n U_i^2 - U_n^2 \\ &= \sum_{i=1}^{n-1} U_i^2 \end{aligned}$$

Da die $\{U_i\}$ u.i.v. $N(0, 1)$ sind, folgt

$$(n - 1)s^2 \sim \chi_{n-1}^2$$

16.5 Die Verteilung von s^2 für allgemeine $N(\mu, \sigma^2)$

Gegeben $\{X_i\}$ u.i.v. $N(\mu, \sigma^2)$

$$\Rightarrow \{Z_i\} \text{ u.i.v. } N(0, 1) \text{ für } Z_i = \frac{X_i - \mu}{\sigma}$$

$$\bar{Z} \sim N(0, 1/n) \Rightarrow \bar{X} \sim N(0, \sigma^2/n)$$

$$\sum_{i=1}^n (Z_i - \bar{Z})^2 \sim \chi_{n-1}^2$$

$$\Rightarrow (n-1)s_Z^2 \sim \chi_{n-1}^2$$

$$\begin{aligned} s_X^2 &= \frac{1}{n-1} \sum_{i=1}^n (X_i - \bar{X})^2 \\ &= \sigma^2 s_Z^2 \end{aligned}$$

$$\Rightarrow \frac{(n-1)s_X^2}{\sigma^2} \sim \chi_{n-1}^2$$

16.6 \bar{X} und s^2

16.6.1 Die Unabhängigkeit von \bar{X} und s^2 für $X_i \sim N(\mu, \sigma^2)$

Für $\{X_i\}$ u.i.v. N sind \bar{X} und s^2 unabhängig. Student (W.S. Gosset) hat es erraten und Fisher hat es bewiesen. Die gemeinsame Dichte von den $\{U_i\}$ ZV, die durch die Helmert Transformation gewonnen worden sind, ist

$$f(u_1, \dots, u_n) = ce^{-\frac{1}{2} \sum u_i^2}$$

da die $\{U_i\}$ u.i.v. $\sim N(0, 1)$

$$\begin{aligned} &= ce^{-\frac{1}{2} \left(\sum_{i=1}^{n-1} u_i^2 + u_n^2 \right)} \\ &= ce^{-\frac{1}{2} \left((n-1)s^2 + n\bar{x}_n^2 \right)} \\ &= g(s^2)h(\bar{x}) \end{aligned}$$

\Rightarrow Unabhängigkeit

16.6.2 Die Verteilung von \bar{X} und s^2 für $n = 2$

X_1, X_2 u.i.v. mit Dichte $g(x)$

$$f_{X_1 X_2}(x_1, x_2) = g(x_1)g(x_2)$$

$$\bar{X} = \frac{1}{2}(X_1 + X_2)$$

$$\begin{aligned} s^2 &= \frac{1}{2-1} \sum_{i=1}^2 (X_i - \bar{X})^2 \\ &= \frac{1}{2}(X_1 - X_2)^2 \end{aligned}$$

Um die gemeinsame Verteilung von \bar{X} und s^2 zu untersuchen, setzen wir

$$Y_1 = \frac{1}{2}(X_1 + X_2) = \bar{X}$$

$$Y_2 = \frac{1}{\sqrt{2}}(X_1 - X_2) = s$$

$$g_{\bar{X}s}(\bar{x}, s) = g\left(\bar{x} + \frac{s}{\sqrt{2}}\right)g\left(\bar{x} - \frac{s}{\sqrt{2}}\right)\sqrt{2}$$

weil $|J| = \sqrt{2}$

Offensichtlich sind \bar{X} und s^2 im allgemeinen nicht unabhängig.

16.6.3 Beispiel für \bar{X} und s^2

$$X \sim E(\lambda)$$

$$g(x) = \lambda^{-\lambda x}$$

$$g_{\bar{X}s}(\bar{x}, s) = \sqrt{2}\lambda^2 e^{-2\lambda\bar{x}}$$

$$0 \leq \bar{X} \quad \text{und} \quad |s| \leq \sqrt{2\bar{X}}$$

Die Marginaldichte von \bar{X} ist

$$\begin{aligned} h(\bar{x}) &= \int_{-\sqrt{2\bar{x}}}^{\sqrt{2\bar{x}}} g_{\bar{X}s}(\bar{x}, s) ds \\ &= \sqrt{2}\lambda^2 e^{-2\lambda\bar{x}} 2\sqrt{2\bar{x}} \\ &= 4\lambda^2 \bar{x} e^{-2\lambda\bar{x}} \end{aligned}$$

wie es natürlich sein sollte (da $\bar{X} = \frac{1}{2}(X_1 + X_2)$).

Obgleich $g_{\bar{X}s}(\bar{x}, s)$ s nicht enthält, sind \bar{X} und s nicht unabhängig. (N.B. Wir haben hier mit $s = \pm\sqrt{s^2}$ gearbeitet, weder mit s^2 , die Stichprobenvarianz, noch mit $|s|$, die Standardabweichung.)

16.7 Kleine Stichproben

Der ZGS ist für n groß gültig. Was kann man mit kleinen Stichproben machen?

Student zeigte, dass

$$T = \frac{\bar{X} - \mu}{s/\sqrt{n}}$$

eine t -Verteilung mit $(n - 1)$ Freiheitsgraden hat, wenn

$$X_i \text{ u.i.v. } \sim N(\mu, \sigma^2)$$

Die t -Verteilung hängt von $(n - 1)$ ab. μ und σ spielen keine Rolle. Dadurch können wir Aussagen über T machen, sogar wenn beide Parameter der Verteilung, μ und σ , unbekannt sind.

16.8 Ableitung der t -Verteilung

Um die Dichte von

$$T = \frac{\bar{X} - \mu}{s/\sqrt{n}}$$

für $\{X_i\}$ u.i.v. $\sim N(\mu, \sigma^2)$ zu finden, benutzen wir die folgenden drei Resultate:

$$(1) \quad \bar{X} \sim N(\mu, \sigma^2/n)$$

$$(2) \quad \frac{(n-1)s^2}{\sigma^2} \sim \chi_{n-1}^2$$

$$(3) \quad \bar{X} \text{ und } s \text{ sind unabhängig.}$$

Wir schreiben

$$T = \frac{\bar{Y} \sqrt{n}}{s_Y}$$

für

$$Y_i = \frac{X_i - \mu}{\sigma} \sim N(0, 1)$$

16.8.1 Transformationen für die t -Verteilung

$$R = \sqrt{n} \bar{Y}$$

$$U = (n - 1)s_Y^2$$

$$V = \frac{U}{n - 1} = s_Y^2$$

$$W = \sqrt{V} = s_Y$$

$$T = \frac{R}{W}$$

Für die letzte Transformation benutzen wir das Resultat:
 X und Y unabhängig mit Dichten $f(x)$ und $g(y)$.
Für $Y > 0$ hat $T = \frac{X}{Y}$ die Dichte

$$h(t) = \int_0^{\infty} f(ty)g(y)ydy$$

$$P(T \leq t) = \int \int_B f(x)g(y)dx dy$$

mit $B = \{(x, y) : x \leq yt\}$. Wir setzen $r = x/y$ und

$$P(T \leq t) = \int_{-\infty}^t \int_0^{\infty} f(ry)g(y)ydy dr = \int_{-\infty}^t h(r)dr$$

16.8.2 Dichten für die t -Verteilung

$$f_R(r) = \frac{1}{\sqrt{2\pi}} e^{-\frac{1}{2}r^2}$$

$$g_U(u) = \frac{1}{2^{\frac{n-1}{2}} \Gamma(\frac{n-1}{2})} u^{\frac{n-1}{2}-1} e^{-\frac{u}{2}}$$

$$g_V(v) = \frac{n-1}{2^{\frac{n-1}{2}} \Gamma(\frac{n-1}{2})} ((n-1)v)^{\frac{n-3}{2}} e^{-\frac{(n-1)v}{2}}$$

$$g_W(w) = \frac{(n-1)w}{2^{\frac{n-3}{2}} \Gamma(\frac{n-1}{2})} ((n-1)w^2)^{\frac{n-3}{2}} e^{-\frac{(n-1)w^2}{2}}$$

$$h_T(t) = \frac{1}{\sqrt{2\pi}} \frac{(n-1)^{\frac{n-1}{2}}}{2^{\frac{n-3}{2}} \Gamma(\frac{n-1}{2})} \int_0^{\infty} e^{-\frac{1}{2}t^2y^2} y^{n-1} e^{-\frac{1}{2}(n-1)y^2} dy$$

$$\Rightarrow h(t) = \frac{\Gamma(\frac{n}{2})}{\Gamma(\frac{n-1}{2})\Gamma(\frac{1}{2})} \frac{1}{\sqrt{n-1}} \left(1 + \frac{t^2}{n-1}\right)^{-\frac{n}{2}}$$

16.9 Verteilungen für Varianztests

Seien $V \sim \chi_m^2$ und $W \sim \chi_n^2$ unabhängig, dann kann man zeigen, dass

$$F = \frac{(V/m)}{(W/n)} \sim F_{m,n}$$

wo die Dichte einer $F_{m,n}$ Verteilung ist, für $x > 0$

$$h_{m,n}(x) = \frac{\Gamma\left(\frac{m+n}{2}\right)}{\Gamma\left(\frac{m}{2}\right)\Gamma\left(\frac{n}{2}\right)} m^{\frac{m}{2}} n^{\frac{n}{2}} \frac{x^{\frac{m}{2}-1}}{(n+mx)^{\frac{m+n}{2}}}$$

und $h_{m,n}(x) = 0$ für $x \leq 0$

Anwendungen

(1) Der Vergleich von zwei Varianzen

(2) Die Varianzanalyse