



Die t-Verteilung

Parameterschätzung, Konfidenzintervall

Seite
1 von 2

© 2004 Prof. Dr.-Ing. T. Harriehausen

Version 3
10.6.2004

Eine wesentliche Aufgabe der mathematischen Statistik ist es, die **Parameter unbekannter Verteilungen** zu ermitteln. Da dies in der Regel nur mittels der Auswertung von **Stichprobendaten** erfolgen kann, spricht man von **Parameterschätzung**. Geht man davon aus, dass die Parameter einer Verteilung einen zwar unbekanntem, prinzipiell aber **eindeutigen Wert** haben, so können ihre auf Grund von Stichproben **geschätzten (empirischen) Werte** selbst als **Zufallsvariable mit einer bestimmten Verteilungsfunktion** aufgefasst werden.

Als Maß für die **Zuverlässigkeit eines Parameters** der Grundgesamtheit, den man auf Grund einer Stichprobe vom Umfang n **geschätzt** hat, dient die Angabe des **Konfidenzintervalls** (Vertrauensintervalls), in dem der richtige Wert des Parameters mit einer bestimmten, anzugebenden **Vertrauenswahrscheinlichkeit** P liegt.

Hier wird nur der in der Technik besonders wichtige Fall einer **normalverteilten Größe** X betrachtet, über deren **Mittelwert** durch Auswertung von Messungen eine seriöse Aussage gemacht werden soll, z.B. „, $U = (1,75 \pm 0,05) \text{ V}$ mit $P = 95\%$ “.

Steht eine **große Stichprobe** (Anhaltswert $n \geq 30$) zur Bestimmung der unbekanntem Parameter **Mittelwert** $E(X) = \mu_x$ und **Standardabweichung** $\sqrt{\text{Var}(X)} = \sigma_x$ zur Verfügung, so können die **Parameter**

empirischer Mittelwert $\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$, (1)

empirische Varianz $s_x^2 = \frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2 = \frac{1}{n-1} \left[\sum_{i=1}^n (x_i^2) - n\bar{x}^2 \right]$ bzw. (2)

empirische Standardabweichung¹ $s_x = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_i - \bar{x})^2} = \sqrt{\frac{1}{n-1} \left[\sum_{i=1}^n (x_i^2) - n\bar{x}^2 \right]}$ (3)

der Stichprobe direkt als Schätzwerte für die unbekanntem Parameter verwendet werden.

Der berechnete Mittelwert \bar{x} ist selbst eine Zufallsvariable, die **normalverteilt** ist mit der

Varianz des Mittelwertes $s_{\bar{x}}^2 = \frac{s_x^2}{n}$ bzw. der (4)

Standardabweichung des Mittelwertes $s_{\bar{x}} = \frac{s_x}{\sqrt{n}}$. (5)

Somit lässt sich aus einer Wertetabelle für die **Standard-Normalverteilung** $\Phi(z)$ die Wahrscheinlichkeit P , dass der gesuchte Wert μ_x im Bereich $\bar{x} - t \cdot s_{\bar{x}} \leq \mu_x \leq \bar{x} + t \cdot s_{\bar{x}}$ liegt, näherungsweise berechnen als

$P\left(\left| \bar{x} - \mu_x \right| \leq t \cdot s_{\bar{x}} \right) = 2\Phi(t) - 1$. (6)

Ist die **Stichprobe klein** (Anhaltswert $n < 30$), so werden die aus den wenigen Messwerten mittels (1) und (3) berechneten empirischen Parameter mit sinkendem n drastisch unsicherer und man muss an Stelle der Standard-Normalverteilung die **t-Verteilung**², verwenden.

¹ Diese Funktion wird auf vielen Taschenrechnern (u.a. auf dem TI 30) mit $\sigma_{x, n-1}$ bezeichnet.

² Diese auch Student-t-Verteilung genannte Verteilung wurde im Jahre 1908 von dem englischen Mathematiker William S. Gosset (1876-1937) unter dem Pseudonym „Student“ veröffentlicht.



Die t-Verteilung

Parameterschätzung, Konfidenzintervall

Während der Wert der Standard-Normalverteilung $\Phi(z)$ nur von einer unabhängigen Variablen $z = \frac{x - \mu_x}{\sigma_x}$ abhängt, ist der Wert der Verteilungsfunktion $F_t(t, k)$ der t-Verteilung

$F_t(t, k) = \int_{-\infty}^t f_t(u, k) du$ mit der Dichtefunktion $f_t(t, k) = A_k (1 + t^2/k)^{-\frac{k+1}{2}}$ von einer unabhängigen Variablen $t = \frac{\bar{x} - \mu_x}{s_{\bar{x}}}$ mit \bar{x} nach (1) und $s_{\bar{x}}$ nach (3) und zusätzlich einem **Parameter**

k mit $k \geq 1$, der **Anzahl der Freiheitsgrade** der Verteilung, abhängig. Somit handelt es sich bei „der“ t-Verteilung eigentlich um eine ganze **Klasse von Verteilungen**: je eine für jeden Wert von k. Je kleiner k ist, desto flacher verläuft die Funktion. Mit steigendem Wert von k nähert sich der Verlauf der t-Verteilung immer mehr dem Verlauf der Standard-Normalverteilung an.

Die Dichtefunktion der t-Verteilung ist eine gerade Funktion. Ihre Kennwerte sind $\mu = 0$ für $k \geq 2$ und $\sigma^2 = \frac{k}{k-2}$ für $k \geq 3$. Der Wert des vom Parameter k abhängigen Faktors A_k in der

Dichtefunktion ergibt sich aus der Normierungsbedingung $\int_{-\infty}^{\infty} f_t(t, k) = 1$.

Ebenso wie die Funktionswerte der Standard-Normalverteilung erhält man die **Funktionswerte** der t-Verteilung **aus Tabellen in der Fachliteratur**. Die Werte der t-Verteilung sind aber nicht als Funktion von t tabelliert. Vielmehr werden diejenigen Werte von t angegeben, die zu einem bestimmten **Parameterpaar** gehören, nämlich dem **Freiheitsgrad** $k = n - 1$ und einem bestimmten **Wahrscheinlichkeitswert**. Diese Wahrscheinlichkeit ist entweder die **Vertrauenswahrscheinlichkeit** P, mit der die Zufallsvariable im Bereich $-t \dots + t$ liegt (z.B. 90%, 95%, 98%, 99%, 99,9%) oder oftmals auch die **halbe Irrtumswahrscheinlichkeit** $\alpha = 0,5(1 - P)$. Es gibt noch diverse andere Darstellungsvarianten.

Tabelle 1 zeigt eine kleine derartige Tabelle, in der als Parameter die Vertrauenswahrscheinlichkeit P verwendet wird. Für $k \rightarrow \infty$ gilt $F_t(k, t) = \Phi(t)$.

Tabelle 1: Ausgewählte Werte des Parameters t

| k | P | | |
|----------|--------|--------|---------|
| | 95% | 99% | 99,9% |
| 1 | 12,706 | 63,657 | 636,619 |
| 2 | 4,303 | 9,925 | 31,598 |
| 3 | 3,182 | 5,841 | 12,924 |
| 4 | 2,776 | 4,604 | 8,610 |
| 5 | 2,571 | 4,032 | 6,869 |
| 6 | 2,447 | 3,707 | 5,959 |
| 7 | 2,365 | 3,499 | 5,408 |
| 8 | 2,306 | 3,355 | 5,041 |
| 9 | 2,262 | 3,250 | 4,781 |
| 10 | 2,228 | 3,169 | 4,587 |
| 15 | 2,131 | 2,947 | 4,073 |
| 20 | 2,086 | 2,845 | 3,890 |
| 25 | 2,060 | 2,787 | 3,725 |
| 30 | 2,042 | 2,750 | 3,646 |
| 40 | 2,021 | 2,704 | 3,551 |
| 50 | 2,010 | 2,678 | 3,496 |
| ∞ | 1,960 | 2,576 | 3,291 |