

# Anhang A

## Appendix: Stetige Verteilungen

In diesem Appendix werden – der üblichen statistischen Praxis folgend – Zufallsvariablen mit Großbuchstaben und Realisationen mit Kleinbuchstaben bezeichnet.

### A.1 Gleichverteilung

Die Gleichverteilung spielt für das Folgende zwar keine große Rolle, aber aufgrund ihrer Einfachheit ist sie aus didaktischen Gründen gut geeignet um die Grundkonzepte zu wiederholen.

Eine *diskrete Zufallsvariable* ist gleichverteilt, wenn jede ihrer möglichen  $m$  Ausprägungen mit gleicher Wahrscheinlichkeit eintritt:

$$f(x) = \Pr[X = x_i] = \frac{1}{m} \quad (i = 1, \dots, m)$$

Die Wahrscheinlichkeitsfunktion der Augenzahl eines Würfels ist z.B.  $\Pr[X = x_i] = 1/6$  für  $(i = 1, \dots, 6)$ .

Für eine *stetige Zufallsvariable* liegen die möglichen Realisationen zwischen den beiden endlichen Grenzen  $a$  und  $b$ . Da für jede Dichtefunktion gilt

$$\int_{-\infty}^{+\infty} f(x) dx = 1$$


folgt für die **Dichtefunktion einer gleichverteilten stetigen Zufallsvariable**  $X$

$$f(x) = \begin{cases} \frac{1}{b-a} & \text{für } a \leq x \leq b \\ 0 & \text{sonst} \end{cases}$$

Die Wahrscheinlichkeit, dass eine Realisation von  $X$  einen Wert zwischen  $x_1$  und  $x_2$  annimmt, ist

$$\int_{x_1}^{x_2} f(x) dx = \Pr[x_1 \leq x \leq x_2] = \frac{(x_2 - x_1)}{b - a}$$

Durch Integration der Dichtefunktion erhält man die **Verteilungsfunktion**  $F(x)$



**Abbildung A.1:** Dichte- und Verteilungsfunktion einer stetigen gleichverteilten Zufallsvariable.

$$F(x) = \begin{cases} 0 & \text{für } x < a \\ \frac{x-a}{b-a} & \text{für } a \leq x \leq b \\ 1 & \text{für } x > b \end{cases}$$

Abbildung A.1 zeigt die Dichte- und Verteilungsfunktion einer stetigen gleichverteilten Zufallsvariable.

Der Erwartungswert ist

$$\begin{aligned} E(X) &= \int_{-\infty}^{+\infty} x f(x) dx = \int_{-\infty}^a x \cdot 0 dx + \int_a^b x f(x) dx + \int_b^{+\infty} x \cdot 0 dx \\ &= \int_a^b x \frac{1}{b-a} dx \\ &= \left. \frac{x^2}{2(b-a)} \right|_a^b \\ &= \frac{b^2 - a^2}{2(b-a)} \\ &= \frac{a+b}{2} \end{aligned}$$

weil  $(b^2 - a^2) = (a+b)(b-a)$ .

Die Varianz  $\text{var}(X) = E[X - E(X)]^2 = E(X^2) - [E(X)]^2$  kann ebenfalls berechnet werden:

$$E(X^2) = \int_a^b x^2 \left( \frac{1}{b-a} \right) dx = \left. \frac{x^3}{3(b-a)} \right|_a^b = \frac{b^3 - a^3}{3(b-a)}$$


Unter Verwendung von  $b^3 - a^3 = (b-a)(a^2 + ab + b^2)$  erhalten wir schließlich

$$\text{var}(X) = \frac{(a^2 + ab + b^2)}{3} - \left( \frac{a+b}{2} \right)^2 = \frac{(a^2 + b^2 - 2ab)}{12} = \frac{(a-b)^2}{12}$$

Die Gleichverteilung ist also durch die zwei Parameter  $a$  und  $b$  vollständig bestimmt.

## A.2 Normalverteilung

Die Normalverteilung spielt in der Ökonometrie eine besondere Rolle, und dies aus mehreren Gründen. Erstens sind viele Variablen in ihren Grundgesamtheiten



**Abbildung A.2:** Dichtefunktionen von normalverteilten Zufallsvariablen mit unterschiedlichem  $\mu$  und  $\sigma^2$ .

‘annähernd’ normalverteilt (z.B. Körpergröße, Intelligenz, Meßfehler, etc.), zweitens können viele andere Verteilungen aus ihr hergeleitet werden (z.B. die  $\chi^2$ -,  $t$ - oder  $F$ -Verteilung), und drittens nähern sich bei sehr großen Beobachtungszahlen andere Verteilungen manchmal der Normalverteilung an (z.B. die Binomialverteilung). Außerdem werden wir später sehen, sind für große Beobachtungszahlen die *Stichprobenkennwertverteilungen* unabhängig von der Verteilung der Grundgesamtheit annähernd normalverteilt (*zentraler Grenzwertsatz*).

Die Normalverteilung ist eine stetige Verteilung mit der Dichte

$$f(x) = \frac{1}{\sqrt{2\pi\sigma^2}} e^{-(1/2)[(x_i-\mu)/\sigma]^2}$$

mit  $\mu$  = Erwartungswert,  $\sigma$  = Standardabweichung von  $X$ ,  $\pi = 3.14159\dots$ ,  $e = 2.71828\dots$

Wenn eine Zufallsvariable  $X$  normalverteilt ist mit Mittelwert  $\mu$  und Varianz  $\sigma^2$ , d.h.

$$\begin{aligned} E(X) &= \mu \\ \text{var}(X) &= \sigma^2 \end{aligned}$$


wird dies üblicherweise geschrieben als

$$X \sim N(\mu, \sigma^2)$$


Abbildung A.2 zeigt drei Dichtefunktionen von normalverteilten Zufallsvariablen mit unterschiedlichem  $\mu$  und  $\sigma^2$ .

### Eigenschaften der Normalverteilung:

1. Die Verteilung ist stetig und symmetrisch um den Erwartungswert  $\mu$ .



**Abbildung A.3:** Dichtefunktion einer normalverteilten Zufallsvariable und % der Fläche darunter.



**Abbildung A.4:** Verteilungsfunktion einer normalverteilten Zufallsvariable.

2. Die Verteilung ist unbeschränkt und erstreckt sich von  $-\infty$  bis  $+\infty$ .
3. Das Maximum der Verteilung liegt beim Mittelwert  $\mu$  und der Wendepunkt bei  $x = \mu \pm \sigma$ . Außerdem gilt:

$$\Pr(\mu - 1.96\sigma < x_i < \mu + 1.96\sigma) \approx 0.95$$

$$\Pr(\mu - 2.57\sigma < x_i < \mu + 2.57\sigma) \approx 0.99$$

4. Die Normalverteilung ist durch die zwei Parameter  $\mu$  und  $\sigma^2$  vollständig spezifiziert, wir schreiben  $X \sim N(\mu, \sigma^2)$ .

Abbildung A.3 zeigt die Dichtefunktion einer Normalverteilung.

Die Verteilungsfunktion einer normalverteilten Zufallsvariable ist in Abbildung A.4 dargestellt.

**Theorem 1** Wenn  $X, Y, \dots, Z$  normal und unabhängig verteilte Zufallsvariablen und  $a, b, \dots, c$  beliebige Konstanten sind, dann ist die Linearkombination  $aX + bY + \dots + cZ$  auch normalverteilt.

Beispiel: Wenn  $X_i \sim N(\mu, \sigma^2)$  mit  $i = 1, 2, 3$  drei *unabhängig* verteilte Zufallsvariablen sind, und dann sind Erwartungswert und Varianz der Zufallsvariable  $W = 2X_1 + X_2 - 4X_3$

$$\begin{aligned} E(W) &= 2E(X_1) + E(X_2) - 4E(X_3) = 2\mu + \mu - 4\mu = -1\mu \\ \text{var}(W) &= 2^2 \text{var}(X_1) + 1^2 \text{var}(X_2) + 4^2 \text{var}(X_3) = 21\sigma^2 \end{aligned}$$

d.h.  $W \sim N(-\mu, 21\sigma^2)$ .

Oder, wenn  $X \sim N(\mu, \sigma^2)$  dann ist  $Y = a + bX \sim N(a + b\mu, b^2\sigma^2)$ , z.B.  $X \sim N(3, 4)$  und  $Y = 2X - 5$  dann ist  $Y \sim N(1, 16)$ .

Dieses Theorem gestattet eine Standardisierung der Normalverteilungen auf einen Mittelwert von Null und eine Standardabweichung von Eins (z-Transformation).

$$z_i = \frac{(x_i - \mu)}{\sigma} \quad \text{bzw.} \quad Z = \frac{(X - \mu)}{\sigma}$$

mit  $Z \sim N(0, 1)$ , man sagt  $Z$  ist *standardnormalverteilt*. Die Tabelle der Standardnormalverteilung findet sich in jedem Statistiklehrbuch.

Wenn  $X$  und  $Y$  gemeinsam normalverteilt sind, dann sind sie unabhängig wenn und nur wenn  $\text{cov}(X, Y) = 0$ . Achtung, dies gilt nur für die Normalverteilung! Sind zwei Zufallsvariablen nicht gemeinsam normalverteilt ist  $\text{cov}(X, Y) = 0$  in der Regel nicht hinreichend um Unabhängigkeit zu garantieren.

**Bivariate Normalverteilung:**  $(X, Y) \sim N(\mu_X, \mu_Y, \sigma_X^2, \sigma_Y^2, \rho)$ ,  $|\rho| \leq 1$  oder in Matrixschreibweise

$$\begin{pmatrix} X \\ Y \end{pmatrix} \sim N \left[ \begin{pmatrix} \mu_X \\ \mu_Y \end{pmatrix}, \begin{pmatrix} \sigma_X^2 & \sigma_{XY} \\ \sigma_{XY} & \sigma_Y^2 \end{pmatrix} \right]$$


mit der Dichtefunktion

$$f(x, y) = \frac{1}{2\pi\sigma_x\sigma_y\sqrt{1-\rho^2}} \exp \left\{ -\frac{1}{2(1-\rho^2)} [z_X^2 - z_X z_Y + z_Y^2] \right\}$$


mit

$$z_X = \frac{x - \mu_X}{\sigma_X}, \quad z_Y = \frac{y - \mu_Y}{\sigma_Y}$$

siehe Abbildung A.5.



$$\mu_X = \mu_Y = 0, \sigma_X^2 = \sigma_Y^2 = 1; \rho = 0$$



$$\mu_X = \mu_Y = 0, \sigma_X^2 = \sigma_Y^2 = 1; \rho = -0.7$$

**Abbildung A.5:** Bivariate Normalverteilungen

**Übungsbeispiele:**

1. Zwei Zufallsvariablen  $X$  und  $Y$  seien bivariat normalverteilt mit  $X \sim N(2, 3)$ ,  $Y \sim N(1, 2)$ , und  $\text{Cov}(X, Y) = 0.5$ . bzw. in Matrixschreibweise

$$\begin{pmatrix} X \\ Y \end{pmatrix} \sim N \left[ \begin{pmatrix} 2 \\ 1 \end{pmatrix}, \begin{pmatrix} 3 & 0.5 \\ 0.5 & 2 \end{pmatrix} \right]$$

Wie ist dann eine Zufallsvariable  $V = 2X + 3Y$  verteilt?

$V$  ist univariat normalverteilt mit

$$\begin{aligned} E(V) &= E(2X + 3Y) = 2E(X) + 3E(Y) \\ &= 2 \times 2 + 3 \times 1 \\ &= 7 \end{aligned}$$

und

$$\begin{aligned} \text{var}(V) &= \text{var}(2X + 3Y) \\ &= \text{var}(2X) + \text{var}(3Y) + 2 \text{cov}(2X, 3Y) \\ &= \underbrace{2^2 \text{var}(X)}_3 + \underbrace{3^2 \text{var}(Y)}_2 + 2 \times 2 \times 3 \underbrace{\text{cov}(X, Y)}_{0.5} \\ &= 12 + 18 + 6 = 36 \end{aligned}$$

Also ist  $V \sim N(7, 36)$ .

Dies kann einfach simuliert werden, z.B. mit R. Der Befehl `mvrnorm` aus dem Packet MASS erzeugt Zufallszahlen (Realisationen) aus einer multivariaten Normalverteilung. Der folgende Code demonstriert das obige Resultat anhand von 10000 Replikationen.

```
library(MASS)
mu = c(2,1)
Sigma <- matrix(c(3,0.5,0.5,2), nrow=2, ncol=2)
set.seed(1234567)
XY <- mvrnorm(n=10000, mu, Sigma)
V <- 2*XY[,1] + 3*XY[,2]
mean(V) # -> 7.05138
var(V) # -> 36.11783
```

2. Erzeugen Sie in einem Computerprogramm zwei unabhängige Zufallsvariablen  $X \sim N(2, 3)$ ,  $Y \sim N(1, 2)$ , und  $\text{cov}(X, Y) = 0$ , d.h.

$$\begin{pmatrix} X \\ Y \end{pmatrix} \sim N \left[ \begin{pmatrix} 2 \\ 1 \end{pmatrix}, \begin{pmatrix} 3 & 0 \\ 0 & 2 \end{pmatrix} \right]$$

mit je 100,000 Beobachtungen, und erzeugen Sie eine Grafik mit den Histogrammen.

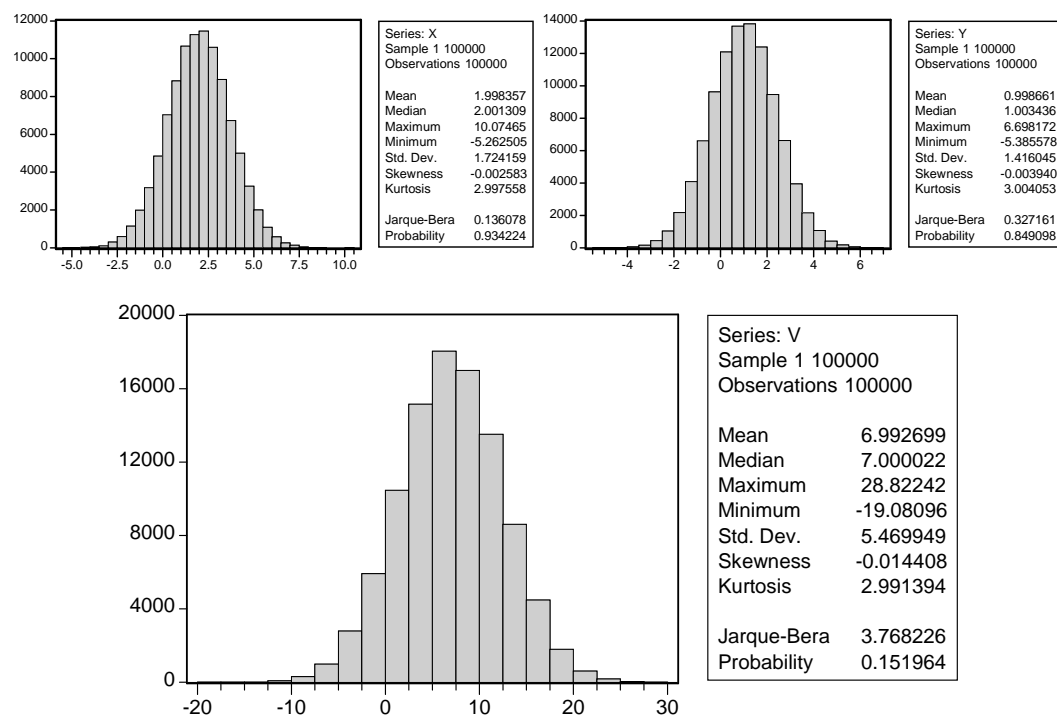
Berechnen Sie  $V = 2X + 3Y$  und zeigen Sie das Histogramm. Welchen Mittelwert und welche Varianz von  $V$  erwarten Sie? Stimmen die erwarteten Werte näherungsweise mit den empirischen Werten überein?

Wenn  $Z \sim N(0, 1)$  ist  $X = 2 + \sqrt{3}Z \sim N(2, 3)$ , da  $\text{var}(X) = \text{var}(2 + \sqrt{3}Z) = \sqrt{3}^2 \text{var}(Z) = 3$ .

In EViews wird eine standardnormalverteilte Zufallszahl z.B. mit der Funktion `@rnorm` erzeugt.

Der folgende EViews Code legt einen Workfile mit dem Namen TEST für 100000 Querschnitts-Beobachtungen (Option `u` für *'undated'*) an und erzeugt die drei Zufallsvariablen (Befehle `series`). Die `freeze`-Befehle erzeugen die Grafiken mit den drei einzelnen Histogrammen, die mit dem `graph` und `merge` Befehl zu einer Grafik zusammengefaßt und mit dem Befehl `show` angezeigt werden.

```
wfcreate(wf=TEST) u 100000
series X = 2 + @sqrt(3)*@rnorm
series Y = 1 + @sqrt(2)*@rnorm
series V = 2*X + 3*Y
freeze(HX) X.hist
freeze(HY) Y.hist
freeze(HV) V.hist
graph GRAFIK.merge HX HY HV
show GRAFIK
```





$$\begin{aligned}
\text{var}(V) &= \text{var}(2X + 3Y) \\
&= \text{var}(2X) + \text{var}(3Y) + 2 \text{cov}(2X, 3Y) \\
&= 2^2 \underbrace{\text{var}(X)}_3 + 3^2 \underbrace{\text{var}(Y)}_2 + 2 \times 2 \times 3 \underbrace{\text{cov}(X, Y)}_0 \\
&= 12 + 18 + 0 = 30 \\
\text{Std.Dev.}(V) = \sqrt{\text{var}(V)} &= \sqrt{30} = 5.477 \approx 5.469949
\end{aligned}$$

### A.3 Die Chi-Quadrat Verteilung:

Die Chi-Quadrat oder  $\chi^2$  Verteilung geht auf den Astronomen F.R. Helmert (1875) zurück.

**Theorem 2** Sind  $Z_1, Z_2, \dots, Z_\nu$  unabhängig standardnormalverteilte Zufallsvariablen (d.h. normalverteilte Zufallsvariable mit Mittelwert 0 und Varianz 1), so folgt die Quadratsumme  $\chi^2 = Z_1^2 + Z_2^2 + \dots + Z_\nu^2$  einer  $\chi^2$  Verteilung mit  $\nu$  Freiheitsgraden.

$$Z_i \sim N(0, 1) \quad \Rightarrow \quad \sum_{i=1}^{\nu} Z_i^2 \sim \chi_\nu^2$$

Die  $\chi^2$  Verteilung ist nicht symmetrisch und abhängig von der Anzahl der Freiheitsgrade  $\nu$ . Da sie eine Quadratsumme ist kann eine  $\chi^2$ -verteilte Zufallsvariable natürlich nie negativ sein. Erwartungswert und Varianz sind

$$\begin{aligned}
E(\chi^2) &= \nu \\
\text{var}(\chi^2) &= 2\nu
\end{aligned}$$

Wenn  $X_1$  und  $X_2$  zwei unabhängig  $\chi^2$ -verteilte Zufallsvariablen mit  $\nu_1$  bzw.  $\nu_2$  Freiheitsgraden sind, so ist die Summe  $X_1 + X_2$  auch  $\chi^2$ -verteilt mit  $\nu_1 + \nu_2$  Freiheitsgraden.

Diese Verteilung wird v.a. für Tests benötigt, die Varianzen von Zufallsvariablen betreffen. Abbildung A.6 zeigt Dichtefunktionen von  $\chi^2$ -verteilten Zufallsvariablen mit unterschiedlichen Freiheitsgraden.

Um dies zu verdeutlichen haben wir in EViews das Quadrat von 100 standardnormalverteilten Variablen mit je 1000 Beobachtungen erzeugt. Abbildung A.7 zeigt ein Histogramm von  $Z_1^2$ , von  $\sum_{i=1}^5 Z_i^2$ ,  $\sum_{i=1}^{10} Z_i^2$  und  $\sum_{i=1}^{100} Z_i^2$ .

Auch wenn Sie das Programm, das Abbildung A.7 erzeugt, im Moment noch nicht verstehen können, so sei es hier doch für eine spätere Referenz wiedergegeben.

```
' Erzeugung von Chi2 - verteilten Variablen.
```

```
wfcreate temp u 1000
```

```
for !i = 1 to 100
```

```
series x{!i} = @rnorm
```




Abbildung A.6: Dichtefunktionen von  $\chi^2$  verteilten Zufallsvariablen mit  $\nu = 1, 3, 5$  und  $10$  Freiheitsgraden.




Abbildung A.7: Histogramme der Summe von quadrierten standardnormalverteilten Zufallsvariablen.

```

series x{!i}q = x{!i}^2
if !i = 1 then
  series sx1q = x1q
else
  !j = !i-1
  series sx{!i}q = x{!i}q + sx{!j}q
endif
if !i = 1 or !i = 5 or !i = 10 or !i = 100 then
  freeze(graph{!i}) sx{!i}q.hist
  graph{!i}.addtext(t)  Chiquadrat Verteilung mit !i Freiheitsgraden
endif
next

graph gr.merge graph1 graph5 graph10 graph100
show gr.align(2,3,1)

```

## A.4 Die t-Verteilung:

Die t- bzw. Studentverteilung verdankt ihren Namen W.S. Gosset, der deren Ableitung 1908 unter dem Pseudonym ‘Student’ veröffentlichte.

**Theorem 3** Sei  $Z$  eine standardnormalverteilte Zufallsvariable [ $Z \sim N(0,1)$ ] und  $V$  eine  $\chi^2$ -verteilte Zufallsvariable mit  $\nu$  Freiheitsgraden [ $V \sim \chi^2(\nu)$ ], wobei  $Z$  und  $V$  unabhängig voneinander verteilt sind, dann ist die Zufallsvariable  $T$

$$t = \frac{Z}{\sqrt{(V/\nu)}} \sim t_\nu$$

t-verteilt mit  $\nu$  Freiheitsgraden.

Wie aus Abbildung A.8 ersichtlich ist die t Verteilung symmetrisch und ‘flacher’ als die Standardnormalverteilung. Sie nähert sich mit steigender Zahl von Freiheitsgraden der Standardnormalverteilung an und ist für  $\nu \geq 120$  nahezu mit dieser identisch.


Weiters ist

$$\begin{aligned} E(t) &= 0 && \text{für } \nu > 1 \\ \text{var}(t) &= \frac{\nu}{\nu - 2} && \text{für } \nu > 2 \end{aligned}$$

Wir werden die t-Verteilung v.a. benötigen, wenn die Varianz der Grundgesamtheit nicht bekannt ist, sondern aus der Stichprobe geschätzt werden muss.

## A.5 Die F-Verteilung:

Die F Verteilung werden wir später häufig benötigen, z.B. für Tests, die mehrere Regressionskoeffizienten betreffen, oder um die Gleichheit zweier Varianzen zu testen. Sie ist nach R.A. Fisher benannt.



**Abbildung A.8:** Dichtefunktionen für  $t$ -verteilte Zufallsvariablen mit  $\nu = 1, 5$  und  $\infty$  Freiheitsgraden.

**Theorem 4** Wenn  $V_1$  und  $V_2$  zwei unabhängig  $\chi^2$ -verteilte Zufallsvariablen mit  $\nu_1$  bzw.  $\nu_2$  Freiheitsgraden sind, dann ist

$$F = \frac{V_1/\nu_1}{V_2/\nu_2} \sim F_{\nu_1, \nu_2}$$

$F$ -verteilt mit  $\nu_1$  Zähler- und  $\nu_2$  Nennerfreiheitsgraden.


Wie aus Abbildung A.9 ersichtlich ist die  $F$  Verteilung schief. Für große  $\nu_1$  und  $\nu_2$  nähert sie sich einer Normalverteilung an.

Man kann zeigen, dass

$$\begin{aligned} E(F_{\nu_1, \nu_2}) &= \frac{\nu_2}{\nu_2 - 2} \quad \text{für } \nu_2 > 2 \\ \text{var}(F_{\nu_1, \nu_2}) &= \frac{2\nu_2^2(\nu_1 + \nu_2 - 2)}{\nu_1(\nu_2 - 2)^2(\nu_2 - 4)} \quad \text{für } \nu_2 > 4 \end{aligned}$$

Das Quadrat einer  $t$ -verteilten Zufallsvariable mit  $\nu$  Freiheitsgraden folgt einer  $F$  Verteilung mit 1 Zähler- und  $\nu$  Nennerfreiheitsgraden, d.h.

$$t_\nu^2 \sim F_{1, \nu}$$



**Abbildung A.9:** Dichtefunktionen für  $F$ -verteilte Zufallsvariablen mit unterschiedlichen Freiheitsgraden.