

Verteilung des Korrelationskoeffizienten r

für zwei unabhängige normalverteilte Merkmale

Studie

Autor: Helmut Vetter

Ort, Datum: Arlesheim, 23.07.2017

Diese Arbeit wurde mit TexLive erstellt. Als Berechnungstool wurde Excel und VBA-Basic verwendet.

Verteilung des Korrelationskoeffizienten r
für zwei unabhängige normalverteilte Merkmale

Autor

Vetter, Helmut
Schillerweg 2
CH-4144 Arlesheim
061 599 51 09
helmut.vetter@fhnw.ch

Auftraggeberschaft

Fachhochschule für Wirtschaft
Wombacher, Dr. Jörg

Arlesheim, Juli 2017

Ehrenwörtliche Erklärung

Ich versichere, dass ich die vorliegende Arbeit selbstständig und ohne Benutzung anderer als der im Literaturverzeichnis angegebenen Quellen und Hilfsmittel angefertigt habe.

Die wörtlich oder inhaltlich den im Literaturverzeichnis aufgeführten Quellen und Hilfsmitteln entnommenen Stellen sind in der Arbeit als Zitat bzw. Paraphrase kenntlich gemacht.

Diese Arbeit ist noch nicht veröffentlicht worden. Sie ist somit weder anderen Interessenten zugänglich gemacht noch einer anderen Prüfungsbehörde vorgelegt worden.

Arlesheim, 23.07.2017



Helmut Vetter

Management Summary

Durch Simulation soll die Verteilung des Korrelationskoeffizienten r zweier unabhängiger normalverteilter Merkmale in Abhängigkeit vom Stichprobenumfang n ermittelt werden. Es wird sich zeigen, dass diese für $n \geq 25$ recht gut einer normalverteilten Zufallsvariable mit $\mu = 0$ und $\sigma = \frac{1}{\sqrt{n-1}}$ entspricht. \hookrightarrow Kapitel 1.

Analytisch ergibt sich, dass die Grösse $t = r \cdot \sqrt{\frac{n-2}{1-r^2}}$ t-verteilt ist mit $d = n - 2$ Freiheitsgraden. An den Simulationen in \hookrightarrow Kapitel 2 ist dies schön zu sehen.

Die Simulationen wurden in Excel und VBA-Basic programmiert. In \hookrightarrow Kapitel 3 ist das Programmcode abgedruckt.

Inhaltsverzeichnis

1	Simulationen für die Zufallsgrösse r bei wachsendem Stichprobenumfang n	1
2	Simulationen für die Zufallsgrösse $r \cdot \sqrt{\frac{n-2}{1-r^2}}$ bei wachsendem Stichprobenumfang n	6
3	Programmcode	8

1 Simulationen für die Zufallsgrösse r bei wachsendem Stichprobenumfang n

Durch jeweils 100'000 Simulation wurde die empirische Wahrscheinlichkeitsdichtefunktion des Korrelationskoeffizienten r zweier unabhängiger normalverteilter Merkmale in Abhängigkeit vom Stichprobenumfang n ermittelt.

Zum Vergleich ist die Wahrscheinlichkeitsdichtefunktion einer normalverteilten Zufallsvariable mit $\mu = 0$ und $\sigma = \frac{1}{\sqrt{n-1}}$ eingezeichnet \leftrightarrow gestrichelte Linie.

Man erkennt, dass für Stichprobenumfänge $n \geq 25$ die empirische Wahrscheinlichkeitsdichte praktisch mit der Dichtefunktion der Normalverteilung übereinstimmt.




Abb. 1: Stichprobenumfang $n=2$, 100'000 Simulationen, Vergleich $N(\mu = 0, \sigma = 1)$




Abb. 2: Stichprobenumfang $n=3$, 100'000 Simulationen, Vergleich $N(\mu = 0, \sigma = 0.7071)$




Abb. 3: Stichprobenumfang $n=4$, 100'000 Simulationen, Vergleich $N(\mu = 0, \sigma = 0.5774)$




Abb. 4: Stichprobenumfang $n=5$, 100'000 Simulationen, Vergleich $N(\mu = 0, \sigma = 0.5)$




Abb. 5: Stichprobenumfang $n=6$, 100'000 Simulationen, Vergleich $N(\mu = 0, \sigma = 0.4472)$




Abb. 6: Stichprobenumfang $n=8$, 100'000 Simulationen, Vergleich $N(\mu = 0, \sigma = 0.378)$




Abb. 7: Stichprobenumfang $n=10$, 100'000 Simulationen, Vergleich $N(\mu = 0, \sigma = 0.3333)$




Abb. 8: Stichprobenumfang $n=12$, 100'000 Simulationen, Vergleich $N(\mu = 0, \sigma = 0.3015)$




Abb. 9: Stichprobenumfang $n=15$, 100'000 Simulationen, Vergleich $N(\mu = 0, \sigma = 0.2673)$




Abb. 10: Stichprobenumfang $n=20$, 100'000 Simulationen, Vergleich $N(\mu = 0, \sigma = 0.2294)$




Abb. 11: Stichprobenumfang $n=25$, 100'000 Simulationen, Vergleich $N(\mu = 0, \sigma = 0.2041)$




Abb. 12: Stichprobenumfang $n=30$, 100'000 Simulationen, Vergleich $N(\mu = 0, \sigma = 0.1857)$




Abb. 13: Stichprobenumfang $n=40$, 100'000 Simulationen, Vergleich $N(\mu = 0, \sigma = 0.1601)$




Abb. 14: Stichprobenumfang $n=50$, 100'000 Simulationen, Vergleich $N(\mu = 0, \sigma = 0.1429)$




Abb. 15: Stichprobenumfang $n=100$, 100'000 Simulationen, Vergleich $N(\mu = 0, \sigma = 0.1005)$

2 Simulationen für die Zufallsgrösse $r \cdot \sqrt{\frac{n-2}{1-r^2}}$ bei wachsendem Stichprobenumfang n

Durch jeweils 100'000 Simulation wurde die empirische Wahrscheinlichkeitsdichtefunktion der Zufallsvariablen $r \cdot \sqrt{\frac{n-2}{1-r^2}}$ zweier unabhängiger normalverteilter Merkmale in Abhängigkeit vom Stichprobenumfang n ermittelt.

Zum Vergleich ist die (theoretisch korrekte) Wahrscheinlichkeitsdichtefunktion einer t-verteilten Zufallsvariable mit $d = n-2$ Freiheitsgraden eingezeichnet \hookrightarrow gestichelte Linie.

Für $n = 2$ ist die Zufallsvariable $r \cdot \sqrt{\frac{n-2}{1-r^2}}$ nicht definiert, da sich in diesem Fall stets $r = \pm 1$ und also $1-r^2 = 0$ ergeben.




Abb. 16: Stichprobenumfang $n=3$, 100'000 Simulationen, Vergleich $T(d=1)$




Abb. 17: Stichprobenumfang $n=4$, 100'000 Simulationen, Vergleich $T(d=2)$




Abb. 18: Stichprobenumfang $n=5$, 100'000 Simulationen, Vergleich $T(d=3)$




Abb. 19: Stichprobenumfang $n=10$, 100'000 Simulationen, Vergleich $T(d=8)$




Abb. 20: Stichprobenumfang $n=20$, 100'000 Simulationen, Vergleich $T(d=18)$




Abb. 21: Stichprobenumfang $n=50$, 100'000 Simulationen, Vergleich $T(d=48)$




Abb. 22: Stichprobenumfang $n=100$, 100'000 Simulationen, Vergleich $T(d=98)$

3 Programmcode

```
Option Explicit
Const KoernungP = 100
Const KoernungQ = 10
Dim P(-KoernungP To KoernungP) As Double
Dim Q(-11 * KoernungQ To 11 * KoernungQ) As Double
```

```
*****
```

```
Sub VerteilungKorr(ByVal n As Integer, ByVal Simulationen As Long) ... simuliert Verteilung von  $r$ .
```

```
Dim k As Long, Wert As Double, NummerP As Integer, NummerQ As Integer
Dim ra As Range, sum2 As Double
Dim x1(-KoernungP To KoernungP) As Double
Dim x2(-KoernungP To KoernungP) As Double
Dim y(-KoernungP To KoernungP) As Double
*****
```

```
For k = 1 To Simulationen
    Wert = Korr(n)
    NummerP = Int(Wert * KoernungP + 0.5)
    P(NummerP) = P(NummerP) + 1
Next k
Set ra = Sheets("tabelle1").Range("A1")
sum2 = 0
For k = -KoernungP To KoernungP
    If k = -KoernungP Then
        x1(k) = -1
        x2(k) = x1(k) + 1 / (2 * KoernungP)
        y(k) = 2 * P(k) * KoernungP / Simulationen
    ElseIf k = KoernungP Then
        x2(k) = 1
        x1(k) = x2(k) - 1 / (2 * KoernungP)
        y(k) = 2 * P(k) * KoernungP / Simulationen
    Else
        x1(k) = (k - 0.5) / KoernungP
        x2(k) = (k + 0.5) / KoernungP
        y(k) = P(k) * KoernungP / Simulationen
    End If
    ra(2 * (KoernungP + k) + 1, 1) = x1(k)
    ra(2 * (KoernungP + k) + 2, 1) = x2(k)
    ra(2 * (KoernungP + k) + 1, 2) = y(k)
    ra(2 * (KoernungP + k) + 2, 2) = y(k)
    sum2 = sum2 + (k / KoernungP) ^ 2 * P(k) / Simulationen
    P(k) = 0
Next k
Sheets("Tabelle1").Range("sigma") = Sqr(sum2 + 1 / (KoernungP ^ 2 * 12))
End Sub
```

```
*****
```

```
Sub VerteilungKorrT(ByVal n As Integer, ByVal Simulationen As Long)
```

... simuliert Verteilung von $r \cdot \frac{n-2}{1-r^2}$.

```
Dim k As Long, Wert As Double, NummerP As Long, NummerQ As Long
```

```
Dim ra As Range, sum2 As Double
```

```
Dim x1(-10 * KoernungQ To 10 * KoernungQ) As Double
```

```
Dim x2(-10 * KoernungQ To 10 * KoernungQ) As Double
```

```
Dim y(-10 * KoernungQ To 10 * KoernungQ) As Double
```

```
*****
```

```
For k = 1 To Simulationen
```

```
Wert = Korr(n)
```

```
If Wert <> -1 And Wert <> 1 Then
```

```
NummerQ = mymax(-11 * KoernungQ, -
```

```
mymin(11 * KoernungQ, Int(Wert * Sqr((n - 2) / (1 - Wert ^ 2)) * KoernungQ + 0.5)))
```

```
Q(NummerQ) = Q(NummerQ) + 1
```

```
End If
```

```
Next k
```

```
Set ra = Sheets("tabelle2").Range("A1")
```

```
sum2 = 0
```

```
For k = -10 * KoernungQ To 10 * KoernungQ
```

```
x1(k) = (k - 1 / 2) / KoernungQ
```

```
x2(k) = (k + 1 / 2) / KoernungQ
```

```
y(k) = Q(k) * KoernungQ / Simulationen
```

```
ra(2 * (10 * KoernungQ + k) + 1, 1) = x1(k)
```

```
ra(2 * (10 * KoernungQ + k) + 2, 1) = x2(k)
```

```
ra(2 * (10 * KoernungQ + k) + 1, 2) = y(k)
```

```
ra(2 * (10 * KoernungQ + k) + 2, 2) = y(k)
```

```
sum2 = sum2 + (k / KoernungQ) ^ 2 * Q(k) / Simulationen
```

```
Q(k) = 0
```

```
Next k
```

```
Sheets("Tabelle2").Range("sigma") = Sqr(sum2 + 1 / (KoernungQ ^ 2 * 12))
```

```
End Sub
```

```
*****
```

```
Function Korr(ByVal n As Integer) As Double
```

... simuliert Korrelationskoeffizienten r .

```
Dim sumx As Double, sumy As Double, sumx2 As Double
```

```
Dim sumy2 As Double, sumxy As Double, rx As Double, ry As Double, i As Integer
```

```
*****
```

```
sumx = 0
```

```
sumy = 0
```

```
sumx2 = 0
```

```
sumxy = 0
```

```
sumy2 = 0
```

```
For i = 1 To n
```

```
rx = ZufallNormal()
```

```
ry = ZufallNormal()
```

```
sumx = sumx + rx
```

```
sumy = sumy + ry
```

```
sumx2 = sumx2 + rx ^ 2
```

```
sumxy = sumxy + rx * ry
```

```
sumy2 = sumy2 + ry ^ 2
```

```
Next i
```

```
Korr = (sumxy * n - sumx * sumy) / Sqr((sumx2 * n - sumx ^ 2) * (sumy2 * n - sumy ^ 2))
```

End Function

Function **ZufallNormal**() As Double

... standardnormalverteilte ZV r .

ZufallNormal = ErrInv(Rnd())

End Function

Function **ErrInv**(ByVal x As Double, Optional ByVal mu As Double = 0, Optional ByVal sigma As Double = 1) As Double

... Hilfsfunktion.

If x = 0 Then

ErrInv = -10

Elseif x = 1 Then

ErrInv = 10

Else

ErrInv = WorksheetFunction.NormInv(x, mu, sigma)

End If

End Function

Function **mymin**(ByVal x As Long, ByVal y As Long) As Long

... Hilfsfunktion.

If x >= y Then

mymin = y

Else

mymin = x

End If

End Function

Function **mymax**(ByVal x As Long, ByVal y As Long) As Long

... Hilfsfunktion.

If x >= y Then

mymax = x

Else

mymax = y

End If

End Function
