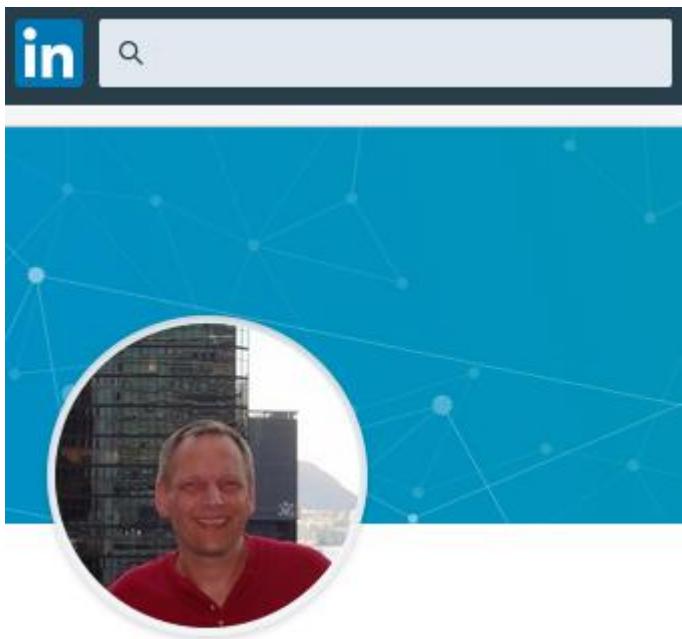




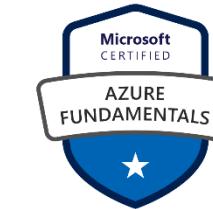
PowerBi & Korrelation

about me

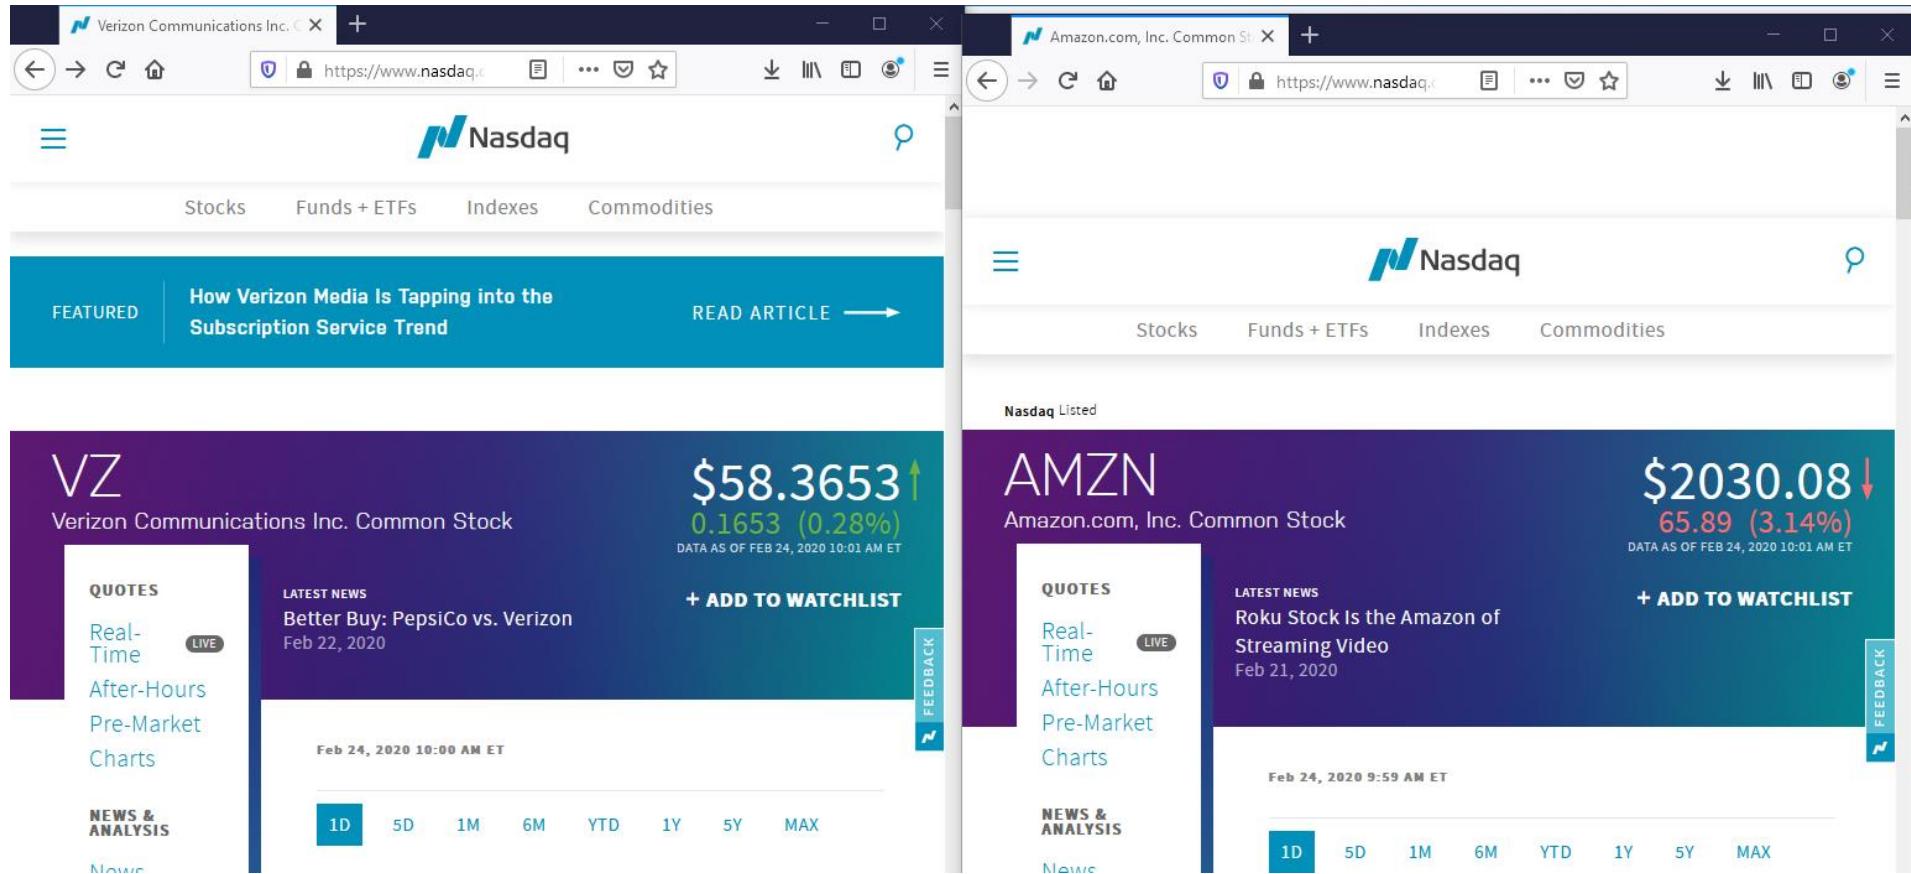


Alexander Karl

<https://www.linkedin.com/in/alexander-karl-44561012a/>



Fragestellungen ...



<https://www.nasdaq.com/market-activity/stocks/amzn>



Fragestellungen ...

ist das Geschäft/ der Geschäftsbereich
“besser” als ...

in bezug auf systematisches und unsystematisches Risiko



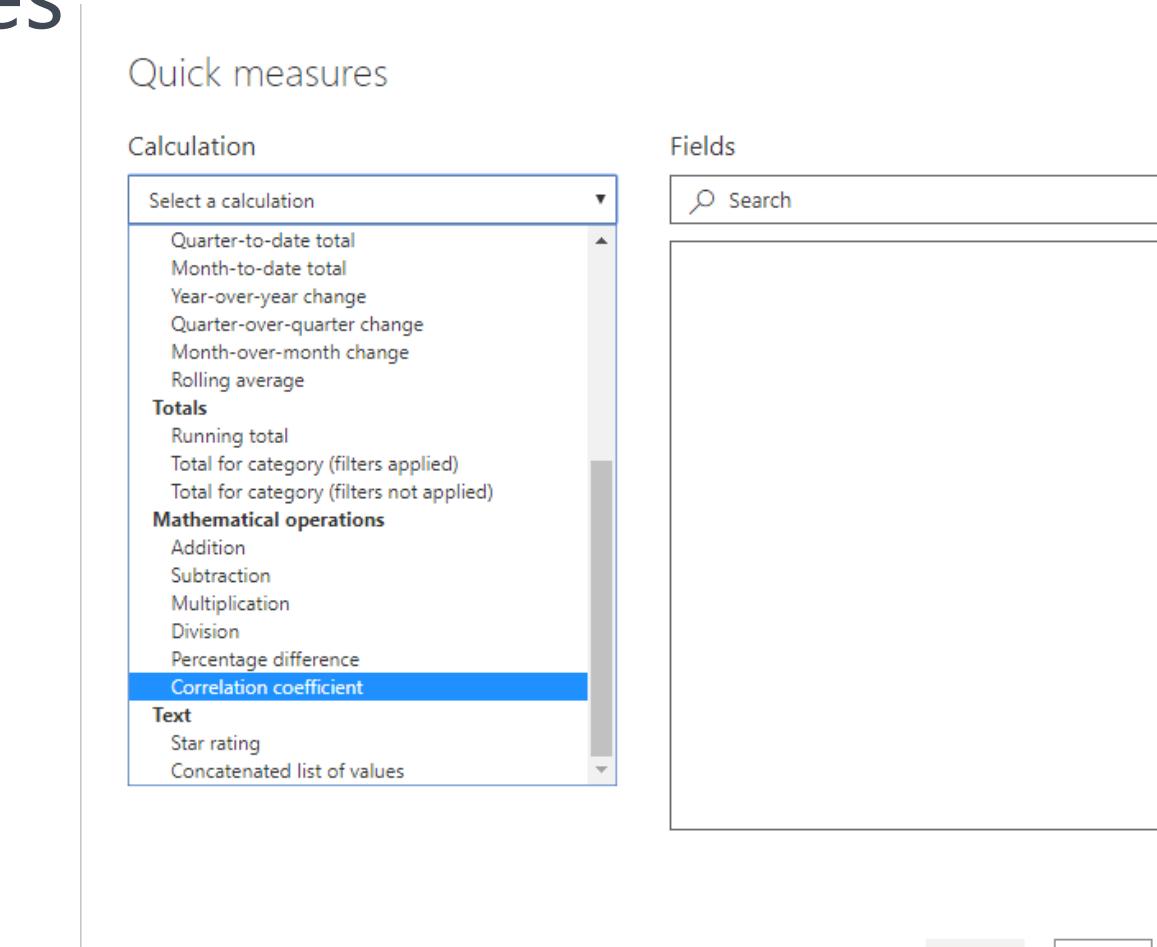
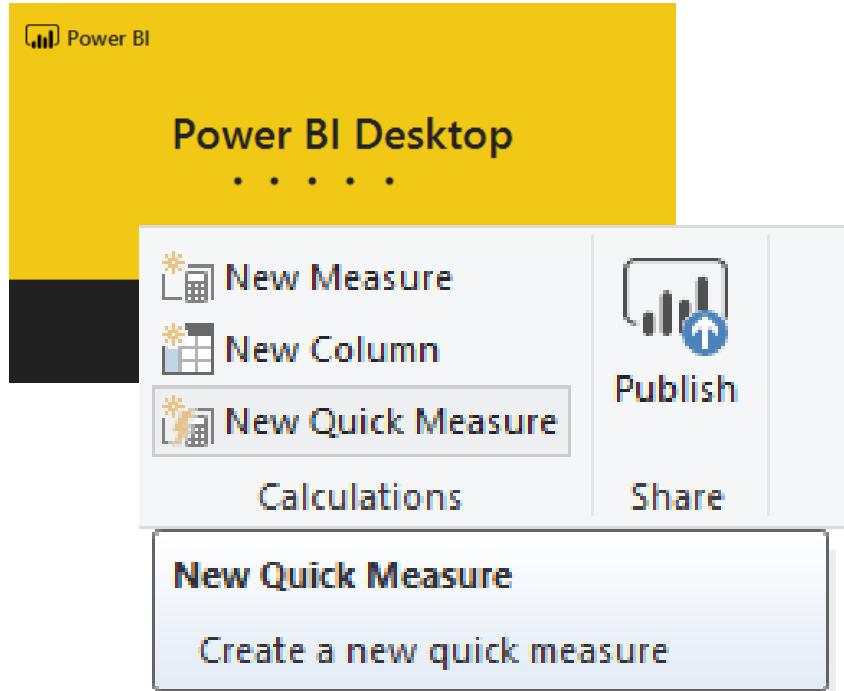
Fragestellungen ...

ist das Geschäft/ der Geschäftsbereich
“besser” als ...

bisher mit Punkt-Vergleich (meist Zeit-Punkt)
Jetzt mit Reihen-Vergleich (meist Zeit-Reihen)



PowerBI Quick Measures



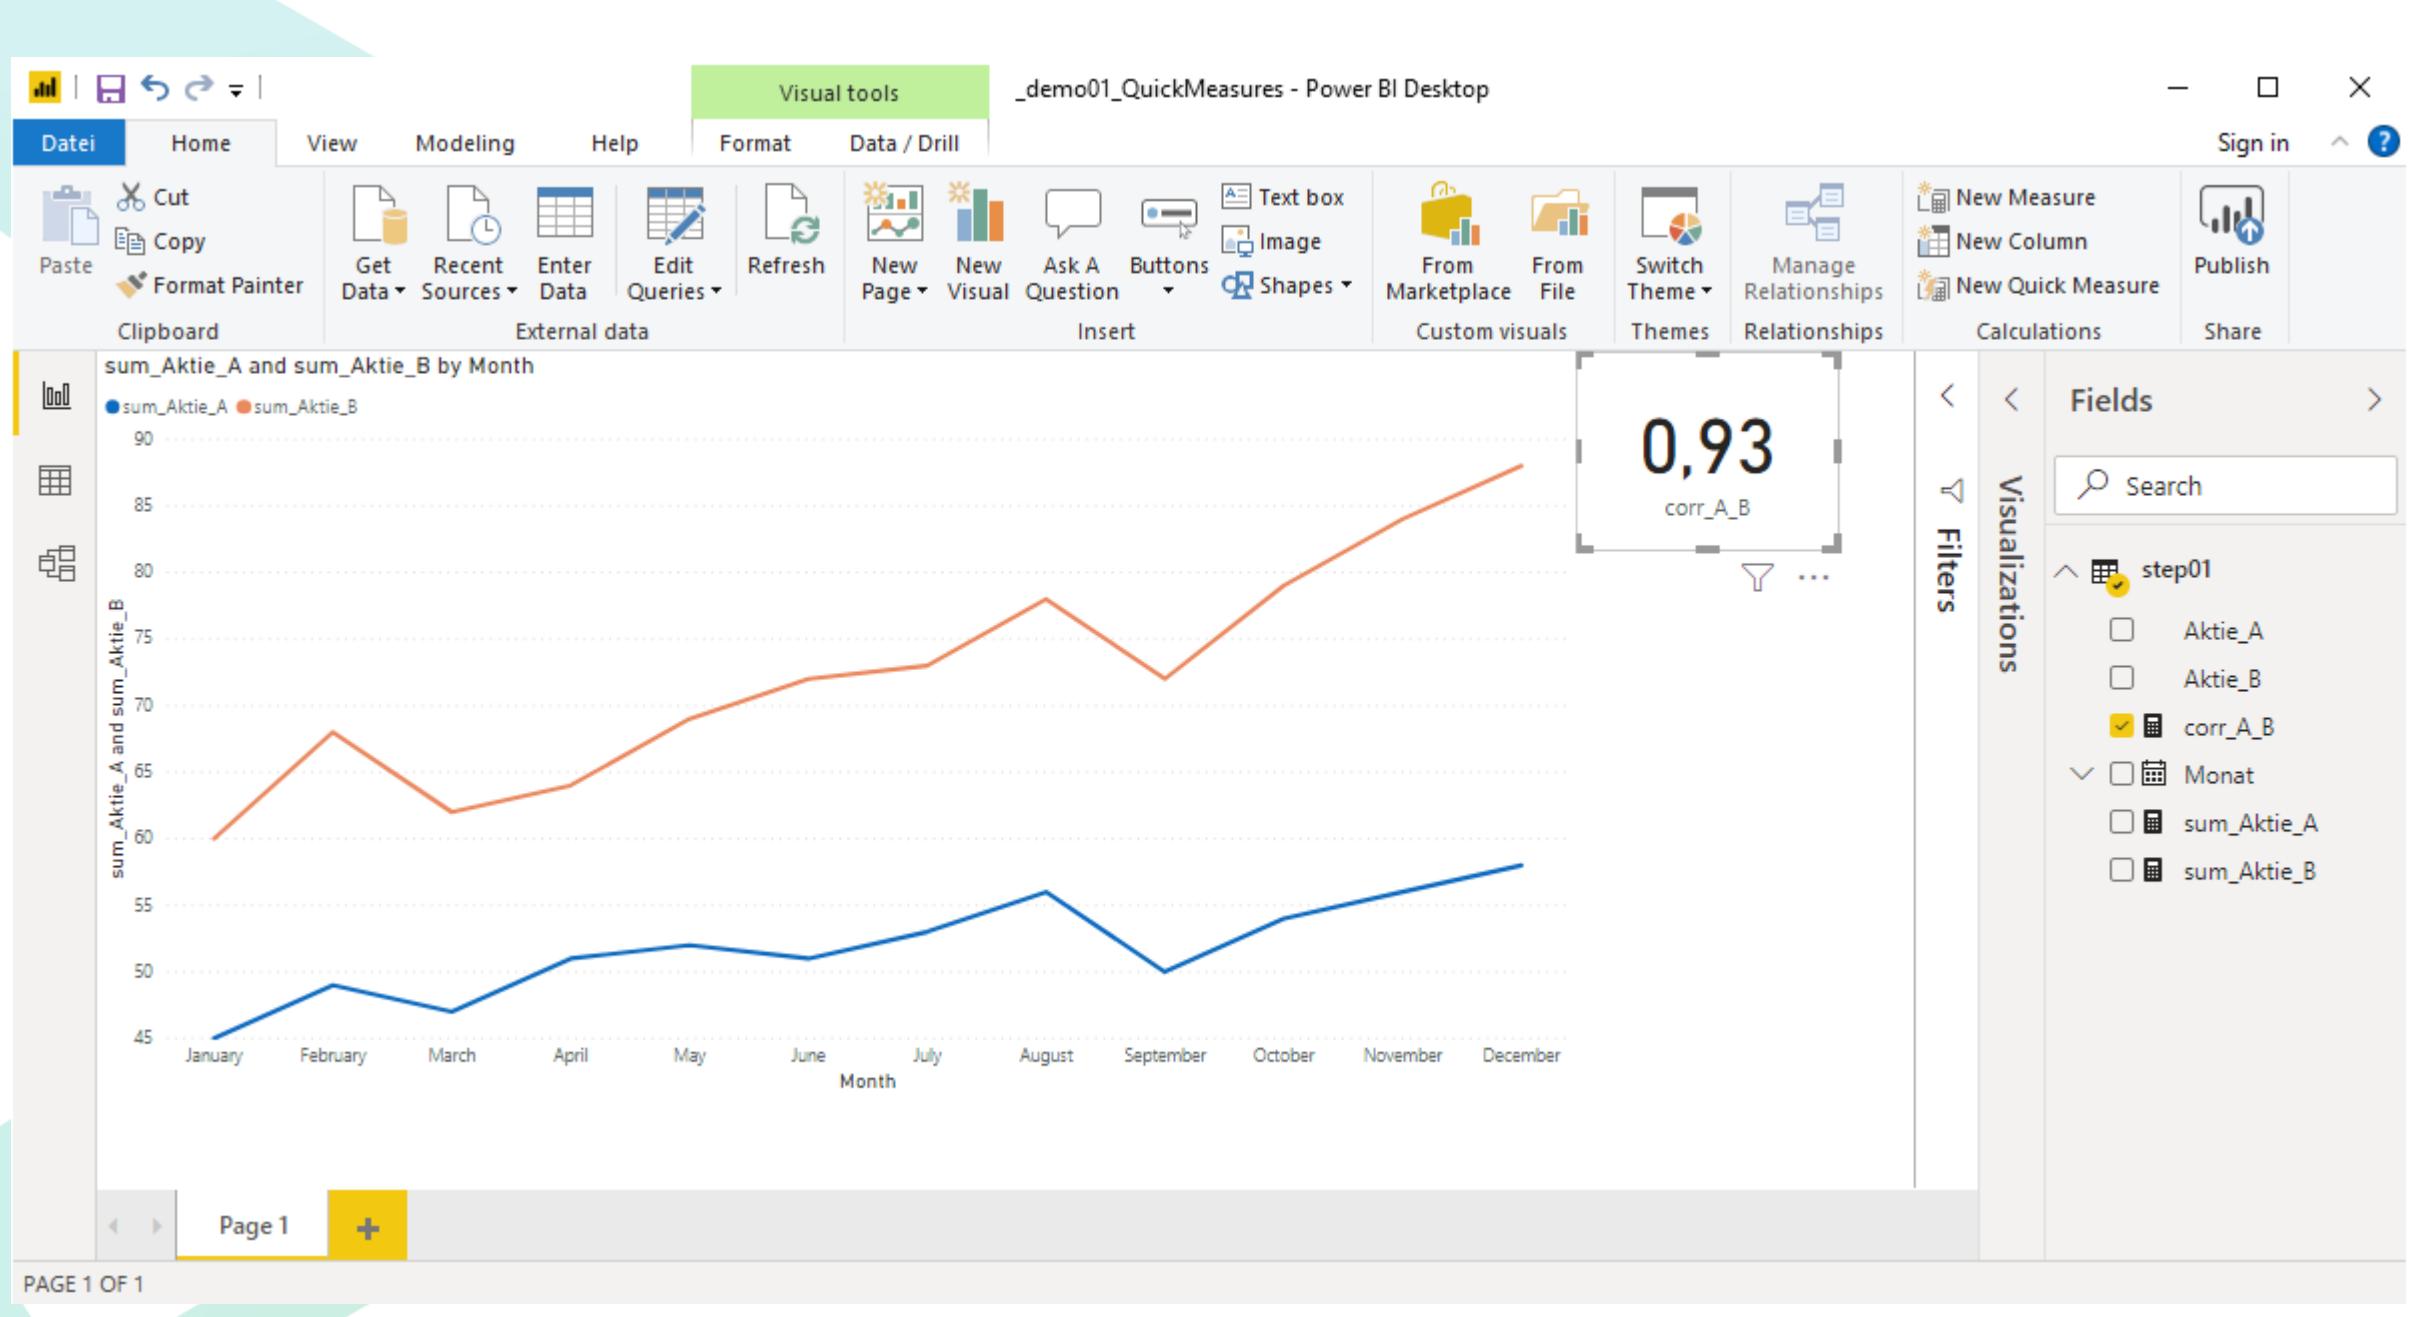
<https://docs.microsoft.com/de-de/power-bi/transform-model/desktop-quick-measures>

<https://community.powerbi.com/t5/Quick-Measures-Gallery/Correlation-coefficient/m-p/196274>

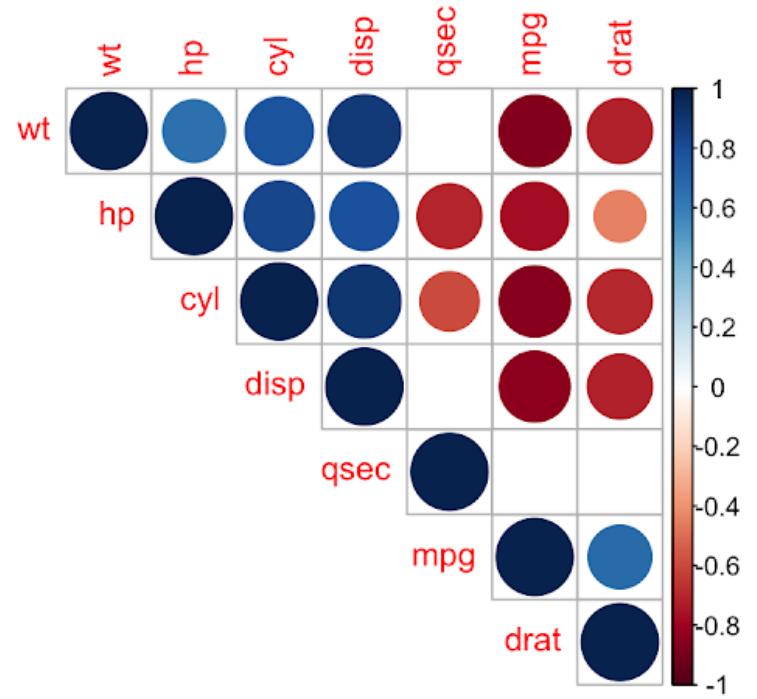




Demo



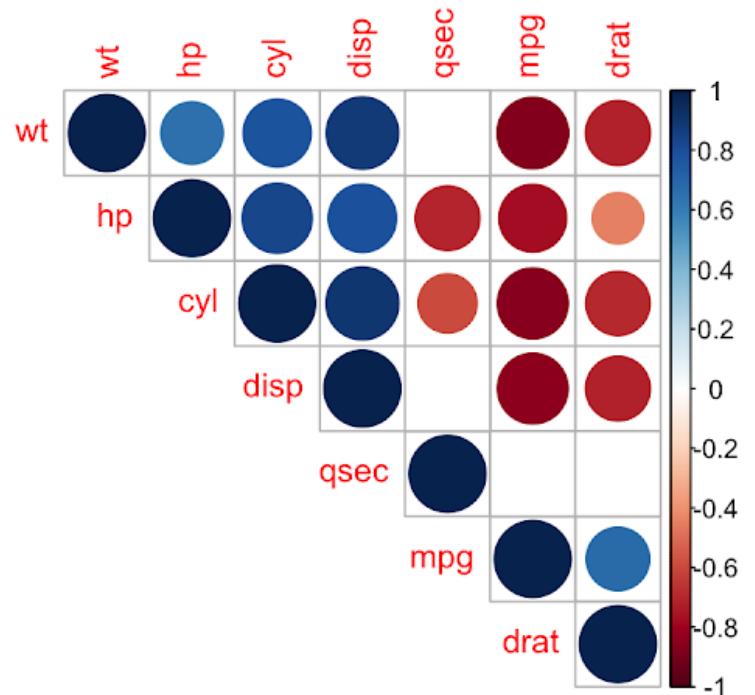
Ausblick mit



	wt	hp	cyl	disp	qsec	vs	mpg	drat	am	gear
carb	0.43	0.75	0.53	0.39	-0.66	-0.57	-0.55	-0.09	0.06	0.27
wt	0.66	0.78	0.89	-0.17	-0.55	-0.87	-0.71	-0.69	-0.58	
hp	0.83	0.79	-0.71	-0.72	-0.78	-0.45	-0.24	-0.13		
cyl	0.9	-0.59	-0.81	-0.85	-0.7	-0.52	-0.49			
disp	-0.43	-0.71	-0.85	-0.71	-0.59	-0.56				
qsec	0.74	0.42	0.09	-0.23	-0.21					
vs	0.66	0.44	0.17	0.21						
mpg	0.68	0.6	0.48							
drat	0.71	0.7								
am	0.79									



Ausblick mit R



RStudio

File Edit Code View Plots Session Build Debug Profile Tools Help

+ Go to file/function Addins

Div_Null.R Untitled1*

Source on Save Run Source

1 ?mtcars

2

A data frame with 32 observations on 11 (numeric) variables.

[, 1] mpg Miles/(US) gallon
[, 2] cyl Number of cylinders
[, 3] disp Displacement (cu.in.)
[, 4] hp Gross horsepower
[, 5] drat Rear axle ratio
[, 6] wt Weight (1000 lbs)
[, 7] qsec 1/4 mile time
[, 8] vs Engine (0 = V-shaped, 1 = straight)
[, 9] am Transmission (0 = automatic, 1 = manual)
[,10] gear Number of forward gears
[,11] carb Number of carburetors



Scalar- and Aggregate-Functions

The image shows two side-by-side screenshots of Microsoft Excel. Both screenshots feature a green ribbon bar at the top with tabs for File, Home, Developer, Insert, Page Layout, Formulas, and Data.

Left Screenshot: This screenshot displays a table with columns labeled A, B, C, and D. The first row contains column headers: ID, Umsatz, Verkaufsdatum, and VerkaufsMonat. The second row contains data: 1, 200, 18.08.2020, and =MONTH(C2). The formula =MONTH(C2) is highlighted with a blue selection box. The formula bar at the top also shows =MONTH(C2).

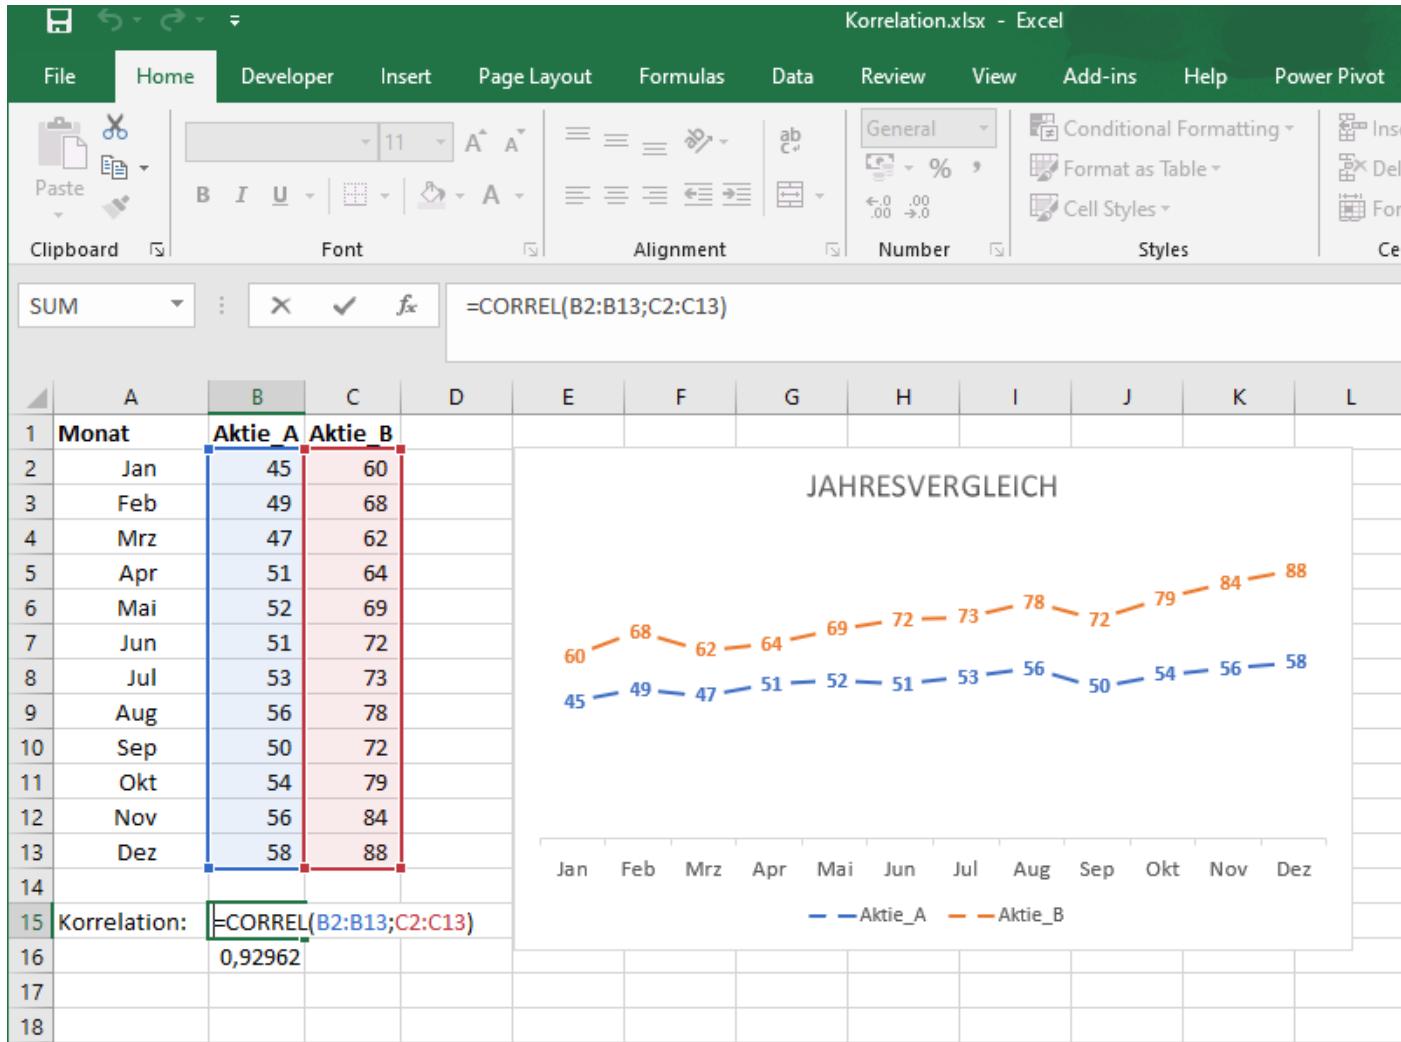
	A	B	C	D
1	ID	Umsatz	Verkaufsdatum	VerkaufsMonat
2	1	200	18.08.2020	=MONTH(C2)
3	2	150	19.08.2020	
4	3	220	20.08.2020	
5	4	300	21.08.2020	
6	5	240	24.08.2020	
7	6	200	25.08.2020	
8	7	180	26.08.2020	
9	8	220	27.08.2020	
10	9	300	28.08.2020	
11	10	240	31.08.2020	
12	11	200	01.09.2020	
13	12	180	02.09.2020	
14	13	240	03.09.2020	
15	14	200	04.09.2020	
16	15	180	07.09.2020	
17				
18				

Right Screenshot: This screenshot shows a table with columns A, B, C, D, and E. The first row contains column headers: ID, Umsatz, Verkaufsdatum, and VerkaufsMonat. The second row contains data: 1, 200, 18.08.2020, and 8. The third row contains data: 2, 150, 19.08.2020, and 8. The fourth row contains data: 3, 220, 20.08.2020, and 8. The fifth row contains data: 4, 300, 21.08.2020, and 8. The sixth row contains data: 5, 240, 24.08.2020, and 8. The seventh row contains data: 6, 200, 25.08.2020, and 8. The eighth row contains data: 7, 180, 26.08.2020, and 8. The ninth row contains data: 8, 220, 27.08.2020, and 8. The tenth row contains data: 9, 300, 28.08.2020, and 8. The eleventh row contains data: 10, 240, 31.08.2020, and 8. The twelfth row contains data: 11, 200, 01.09.2020, and 9. The thirteenth row contains data: 12, 180, 02.09.2020, and 9. The fourteenth row contains data: 13, 240, 03.09.2020, and 9. The fifteenth row contains data: 14, 200, 04.09.2020, and 9. The sixteenth row contains data: 15, 180, 07.09.2020, and 9. The formula bar at the top shows =SUM(B2:B16).

	A	B	C	D	E
1	ID	Umsatz	Verkaufsdatum	VerkaufsMonat	
2	1	200	18.08.2020	8	
3	2	150	19.08.2020	8	
4	3	220	20.08.2020	8	
5	4	300	21.08.2020	8	
6	5	240	24.08.2020	8	
7	6	200	25.08.2020	8	
8	7	180	26.08.2020	8	
9	8	220	27.08.2020	8	
10	9	300	28.08.2020	8	
11	10	240	31.08.2020	8	
12	11	200	01.09.2020	9	
13	12	180	02.09.2020	9	
14	13	240	03.09.2020	9	
15	14	200	04.09.2020	9	
16	15	180	07.09.2020	9	
17			=SUM(B2:B16)		
18			SUM(number1; [number2]; ...)		



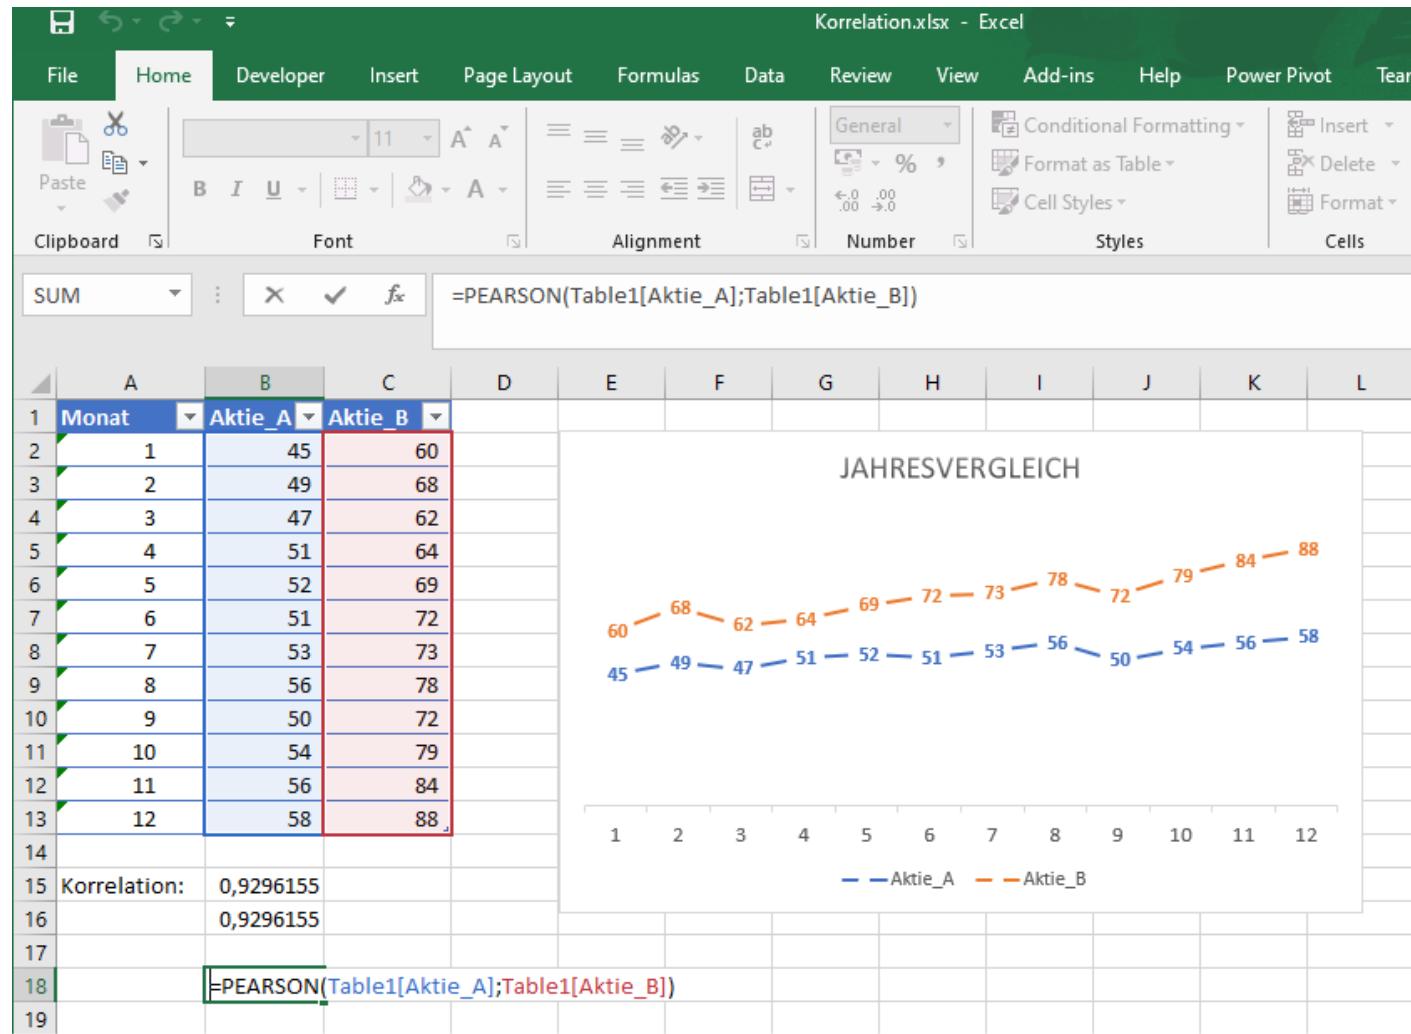
Statistical-Functions



<https://support.microsoft.com/en-us/office/correl-function-995dcef7-0c0a-4bed-a3fb-239d7b68ca92>



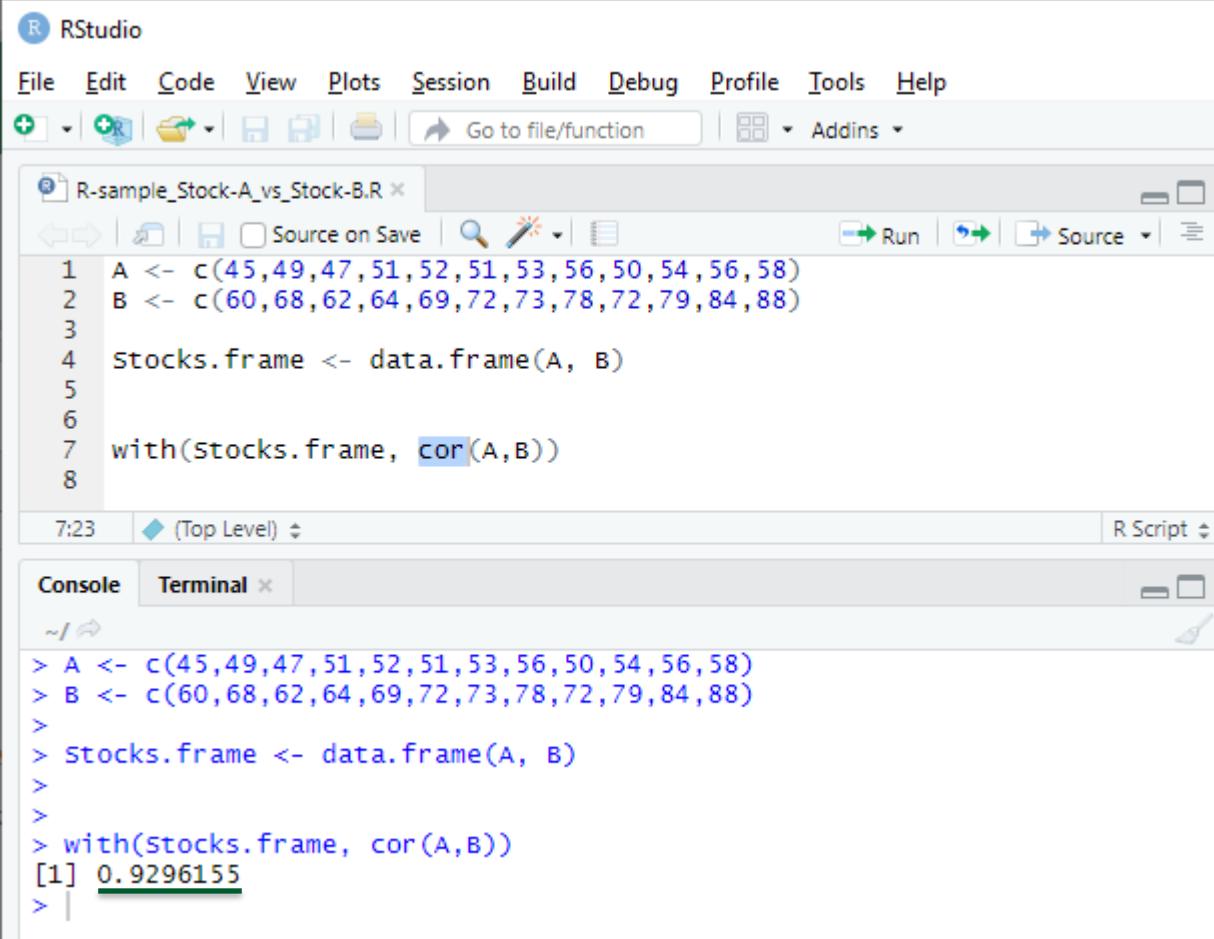
Statistical-Functions



<https://support.microsoft.com/en-us/office/pearson-function-0c3e30fc-e5af-49c4-808a-3ef66e034c18>



Solution with and R-Studio



The screenshot shows the R-Studio IDE interface. The top menu bar includes File, Edit, Code, View, Plots, Session, Build, Debug, Profile, Tools, and Help. Below the menu is a toolbar with various icons. The main area has a script editor titled "R-sample_Stock-A_vs_Stock-B.R" containing the following R code:

```
1 A <- c(45,49,47,51,52,51,53,56,50,54,56,58)
2 B <- c(60,68,62,64,69,72,73,78,72,79,84,88)
3
4 Stocks.frame <- data.frame(A, B)
5
6
7 with(Stocks.frame, cor(A,B))
8
```

The status bar at the bottom left shows "7:23" and "(Top Level)". The status bar at the bottom right shows "R Script". Below the script editor is a "Console" tab, which displays the same R code and its output:

```
> A <- c(45,49,47,51,52,51,53,56,50,54,56,58)
> B <- c(60,68,62,64,69,72,73,78,72,79,84,88)
>
> Stocks.frame <- data.frame(A, B)
>
>
> with(Stocks.frame, cor(A,B))
[1] 0.9296155
>
```



Grundlagen Statistik

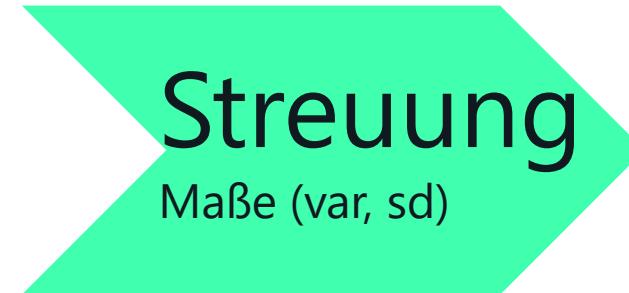
von den Daten zur Formel ...



Daten
Skalenniveau



Lage
Parameter



Streuung
Maße (var, sd)



Skalierungen

- Nominalskala → Cramer's V
 - Geschlecht, Haarfarbe
- Ordinalskala → Spearman
 - Bildung einer Rangfolge ist möglich
- Kardinalskala → Pearson
 - Gewicht, Einkommen, etc.

<https://studyflix.de/statistik/skalenniveaus-1050>



Lageparameter

Überblick der Lageparameter

Arithmetisches Mittel

(auch: Mittelwert oder Durchschnittswert)

(Average)

→ statistischer Durchschnittswert

→ Zur Berechnung addieren wir alle Beobachtungsdaten und teilen dann die Summe durch die Anzahl der Daten.

Beispiel

Die Körpergröße von acht Personen (in cm): 150, 155, 160, 165, 170, 175, 180, 185

Arithmetisches Mittel: 167.5

Median

→ Wert, der genau in der Mitte einer Datenreihe liegt, die nach der Größe geordnet ist

Beispiel

geordnete Datenreihe: 10, 20, 30, 40, 50, 60, 70

Median: 40



Streuungsmaße

Varianz & Standardabweichung

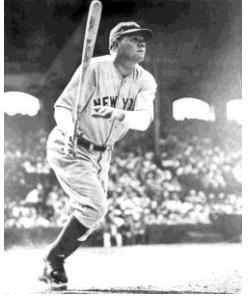
Varianz_Standard-Abweichung.xlsx - Excel

The screenshot shows an Excel spreadsheet titled "Varianz_Standard-Abweichung.xlsx". The ribbon is visible at the top with tabs for File, Home, Developer, Insert, Page Layout, Formulas, Data, Review, View, Add-ins, Help, and Power Pivot. The "Home" tab is selected. The formula bar shows the cell reference D19. The main content is a table comparing two groups of measurements:

	A	B	C	D	E	F	G	H
1	Abweichung				Abweichung	Quad. Abweichung		
2	Größe Gruppe A			Größe Gruppe B				
3	122 cm		0 cm	127 cm		5 cm	25 cm ²	
4	122 cm		0 cm	120 cm		-2 cm	4 cm ²	
5	122 cm		0 cm	132 cm		10 cm	100 cm ²	
6	122 cm		0 cm	117 cm		-5 cm	25 cm ²	
7	122 cm		0 cm	114 cm		-8 cm	64 cm ²	
8								
9	122 cm		0 cm	SUM	122 cm	0 cm	218 cm ²	Varianz
10			0 cm	AVERAGE		0 cm	14,8 cm	Standardabweichung
11								
12	Null-Eigenschaft des arithmetischen Mittels.							
13								
14								



Babe Ruth vs. Barry Bonds



Wer ist erfolgreicher ?

Babe Ruth erzielte 1927 60 Homeruns,
Barry Bonds im Jahr 2001 73 Homeruns ?

präziser ...

Wer war "mit Abstand" besser ?



Babe Ruth vs. Barry Bonds



Jahr	1927	2001
Besten 50		
Durchschnitt	12,68 Homeruns	37,02 Homeruns
Standardabweich.	10,49	9,64
	$\frac{60 - 12,68}{10,49}$	$\frac{73 - 37,02}{9,64}$
Z-Wert	4,51	3,73



Formel Korrelation

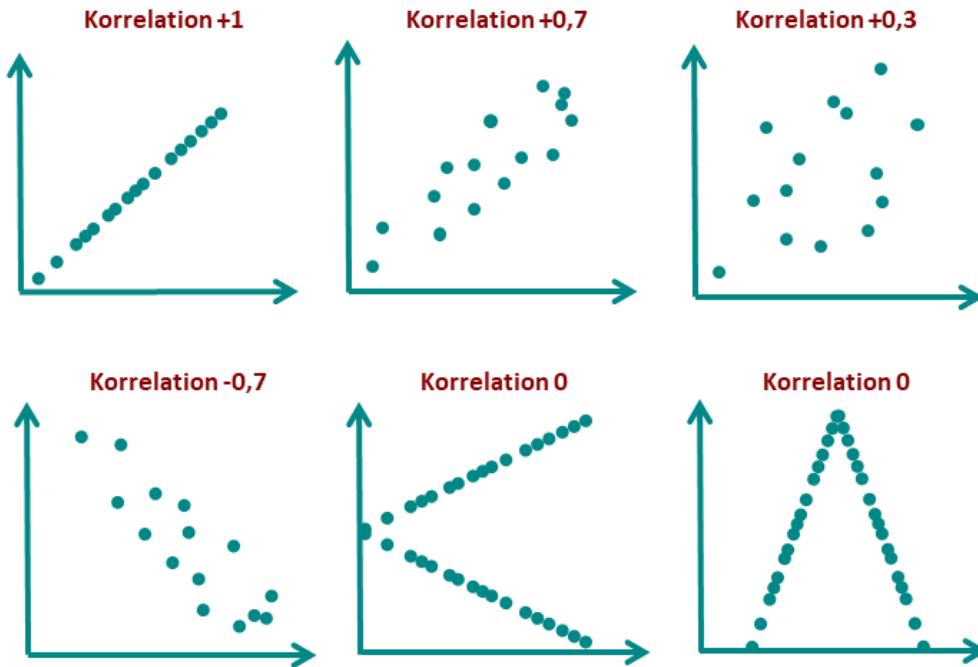
Formel zum Korrelationskoeffizient nach Pearson

$$r = \frac{\sum(x_i - \bar{x})(y_i - \bar{y})}{(N - 1) s_x s_y} = \frac{s_{xy}}{s_x s_y}$$

r	Korrelationskoeffizient
x_i	Beobachtungswerte der Variable x
y_i	Beobachtungswerte der Variable y
\bar{x}	Arithmetisches Mittel aller Wert von x
\bar{y}	Arithmetisches Mittel aller Wert von y
N	Gesamtanzahl
s_{xy}	Kovarianz der Variablen x und y
s_x	Standardabweichung der Variable x
s_y	Standardabweichung der Variable y



Interpretation der Ergebnisse



Betrag von r	Stärke des Zusammenhangs
$0,0 < 0,1$	kein Zusammenhang
$0,1 < 0,3$	geringer Zusammenhang
$0,3 < 0,5$	mittlerer Zusammenhang
$0,5 < 0,7$	hoher Zusammenhang
$0,7 < 1$	sehr hoher Zusammenhang

<https://datatab.de/tutorial/korrelation>



weitere statistische Anmerkungen

griechische

vs.

lateinische Buchstaben

>> **Grundgesamtheit**

Stichprobe

Varianz:

$$\gg \sigma^2 = \frac{\sum(X - \bar{X})^2}{N}$$

$$s^2 = \frac{\sum(X - \bar{X})^2}{N-1}$$

Standardabweichung:

$$\gg \sigma = \sqrt{\sigma^2} = \sqrt{\frac{\sum(X - \bar{X})^2}{N}}$$

$$s = \sqrt{s^2} = \sqrt{\frac{\sum(X - \bar{X})^2}{N-1}}$$



Besonderheiten >> #Div/0!

Screenshot of Microsoft Excel showing a formula error (#DIV/0!) in cell F15.

The formula bar shows the formula `=CORREL(A3:A7;D3:D7)`.

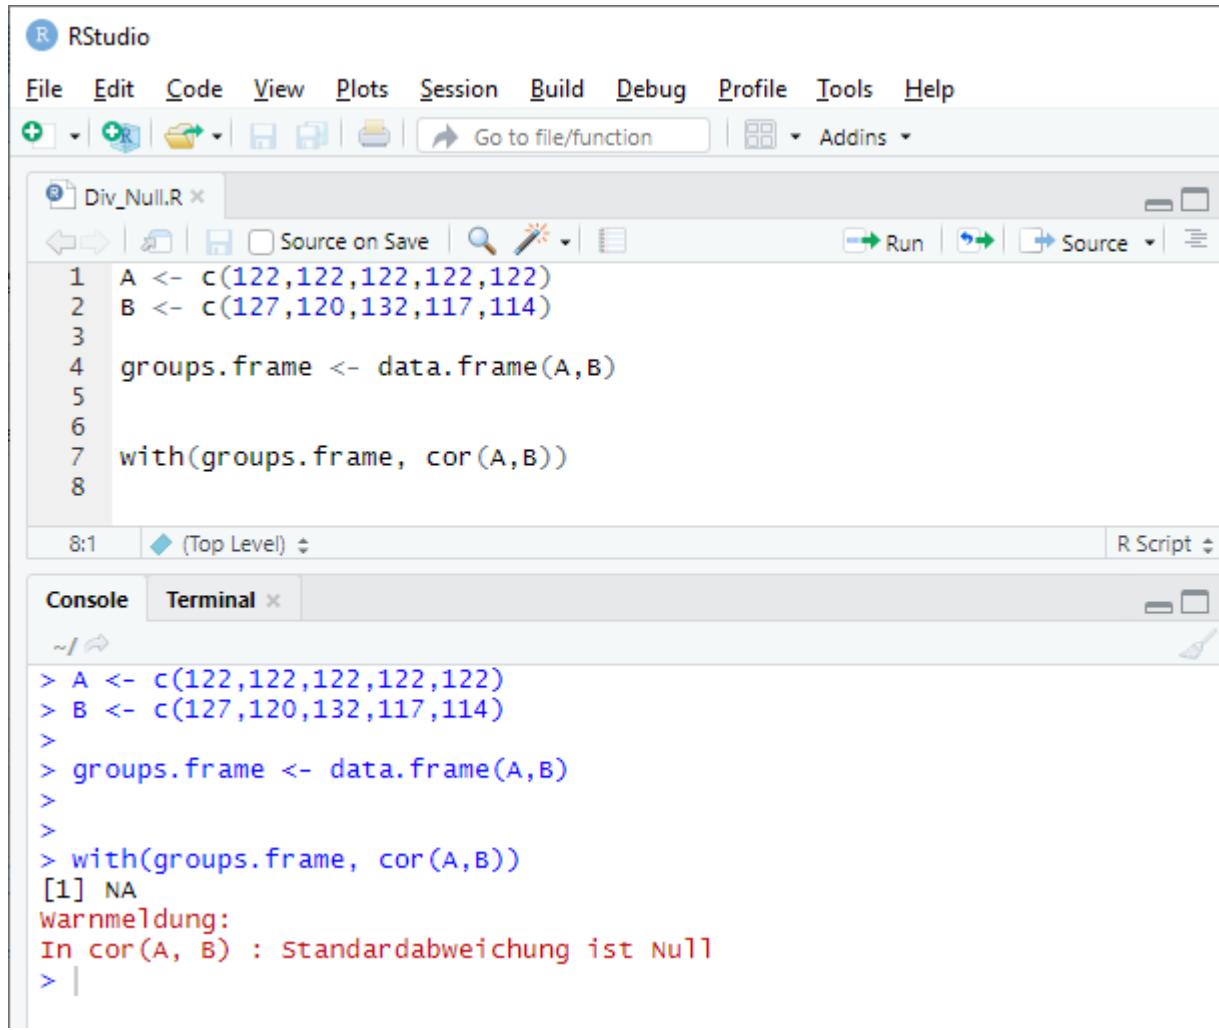
The spreadsheet contains two groups of data:

	A	B	C	D	E	F	G
1		Abweichung			Abweichung	Quad. Abweichung	
2	Größe Gruppe A			Größe Gruppe B			
3	122 cm	0 cm		127 cm	5 cm	25 cm ²	
4	122 cm	0 cm		120 cm	-2 cm	4 cm ²	
5	122 cm	0 cm		132 cm	10 cm	100 cm ²	
6	122 cm	0 cm		117 cm	-5 cm	25 cm ²	
7	122 cm	0 cm		114 cm	-8 cm	64 cm ²	
8							
14							
15	=CORREL(A3:A7;D3:D7)						
16	CORREL(array1; array2)			#DIV/0!			
17							
18							

Cell F15 displays the error message `#DIV/0!`. The formula bar also shows the formula `=CORREL(array1; array2)`.



Besonderheiten >> #Div/0!



The screenshot shows the RStudio interface with a script file named "Div_Null.R" and a console window.

Script Editor (Div_Null.R):

```
1 A <- c(122,122,122,122,122)
2 B <- c(127,120,132,117,114)
3
4 groups.frame <- data.frame(A,B)
5
6
7 with(groups.frame, cor(A,B))
8
```

Console:

```
> A <- c(122,122,122,122,122)
> B <- c(127,120,132,117,114)
>
> groups.frame <- data.frame(A,B)
>
>
> with(groups.frame, cor(A,B))
[1] NA
Warnmeldung:
In cor(A, B) : Standardabweichung ist Null
>
```



Besonderheiten

Screenshot of Power BI Desktop showing a line chart and an R script editor error message.

The chart displays two data series over time (X-axis from 2017-11-06 to 2019-07-31). The left Y-axis ranges from 2400 to 3000, and the right Y-axis ranges from 10 to 35. The blue line generally trends upwards, while the red line shows more volatility and higher peaks.

The R script editor window at the bottom shows the following error message:

Can't display this visual.

No image was created. The R code didn't result in creation of any visuals. Make sure your R script results in a plot to the R default device.

[See details](#)

[Copy details](#)

[Send a Frown](#) [Close](#)

The ribbon menu is visible at the top, showing tabs like Datei, Home, View, Modeling, Help, Format, Data / Drill, Visual tools, and others. The Visual tools tab is selected.



Berechnungen für Measure-“Kombinationen”

W Gaußsche Summenformel – Wi +

https://de.wikipedia.org/wiki/Gaußsche_Summenformel

Man braucht nun nur mehr die Anzahl $n \cdot (n + 1)$ aller Kästchen zu halbieren, was sofort zur gesuchten Anzahl $\frac{n \cdot (n + 1)}{2}$ der grünen Kästchen führt.

Herkunft der Bezeichnung [Bearbeiten | Quelltext bearbeiten]

Diese Summenformel wie auch die Summenformel für die ersten n Quadratzahlen war bereits in der vorgriechischen Mathematik bekannt.

Carl Friedrich Gauß entdeckte diese Formel als neunjähriger Schüler wieder. Die Geschichte ist durch Wolfgang Sartorius von Waltershausen überliefert:

„Der junge Gauss war kaum in die Rechenklasse eingetreten, als Büttner die Summation einer arithmetischen Reihe aufgab. Die Aufgabe war indess kaum ausgesprochen als Gauss die Tafel mit den im niedern Braunschweiger Dialekt gesprochenen Worten auf den Tisch wirft: »Ligget se!« (Da liegt sie.)“
– WOLFGANG SARTORIUS VON WALTERSHAUSEN^[1]



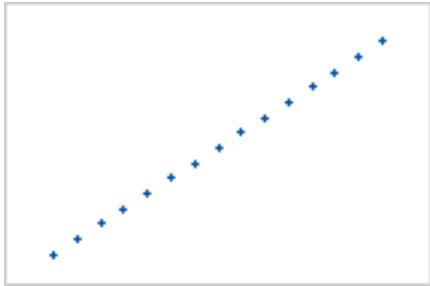
Pearson vs. Spearman's Rank Correlation abhängig vom Skalenniveau

- Nominalskala → Cramer's V
 - Geschlecht, Haarfarbe
- Ordinalskala → Spearman
 - Bildung einer Rangfolge ist möglich
- Kardinalskala → Pearson
 - Gewicht, Einkommen, etc.

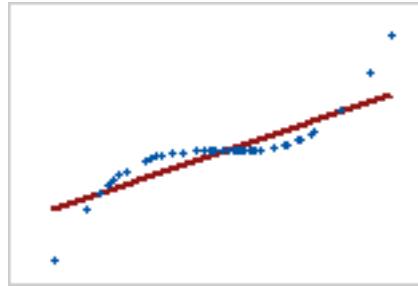
<https://studyflix.de/statistik/skalenniveaus-1050>



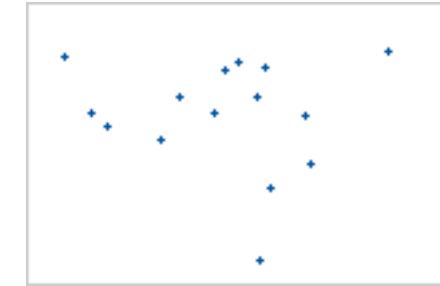
Pearson vs. Spearman's Rank Correlation



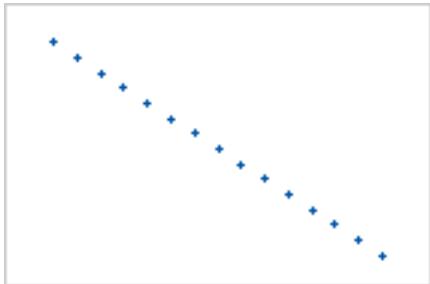
Pearson = +1, Spearman = +1



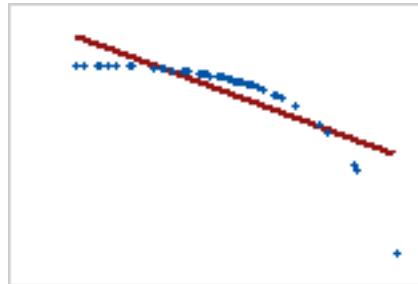
Pearson = +0,851, Spearman = +1



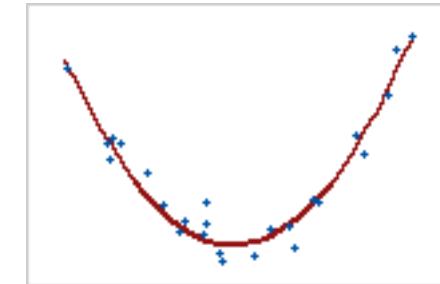
Pearson = -0,093, Spearman = -0,093



Pearson = -1, Spearman = -1



Pearson = -0,799, Spearman = -1



Koeffizient von 0





Demo

```
1 ##install.packages('RODBC')
2 library(RODBC)
3 ##install.packages('corrplot')
4 library(corrplot)
5
6 dbhandle <- odbcDriverConnect("driver={SQL Server};server=localhost;database=eodData;trusted_connection=true")
7 sqltab <- sqlQuery(dbhandle, "select [AAPL],[AMZN],[ATVI],[COST],[MSFT],[MDLZ],[SBUX] from dbo.corrTable")
8
9 M <- cor(sqltab) ## M like Matrix
10
11 #####
12 ## is a wrapped function for mixed visualization style.
13 corrplot.mixed(N)
14
15
16 #####
```



Zusammenfassung:

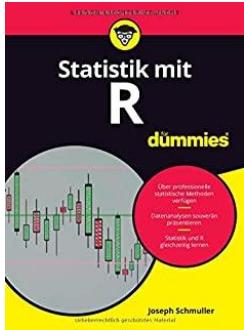
PowerBI Quick Measures (limitiert auf 2 Measures)

Excel (limitiert auf 2 arrays)

R integration (sehr gute graphische Umsetzung)



weitere links & Empfehlungen



https://www.amazon.de/Statistik-mit-R-f%C3%BCr-Dummies/dp/3527713980/ref=sr_1_5

<https://www.scribbr.de/statistik/korrelation/>

<https://www.scribbr.de/statistik/korrelationskoeffizient/>

<https://www.scribbr.de/statistik/lageparameter/>

<https://www.scribbr.de/statistik/streuungsmasse/>

<https://datatab.de/tutorial/korrelation>

<http://www.sthda.com/english/wiki/visualize-correlation-matrix-using-correlogram>

<https://cran.r-project.org/web/packages/corrplot/vignettes/corrplot-intro.html>

<https://de.excel-translator.de/mittelwert/>

<https://support.microsoft.com/en-us/office/excel-functions-alphabetical-b3944572-255d-4efb-bb96-c6d90033e188>



Korrelationsanalyse - Databab

https://databab.de/tutorial/korrelation

DATAtab Statistik Rechner Diagramme Tutorial Statistik-Kurs Premium FAQ Login EN DE

Get Started → Hier geht's zum **Online Statistik Rechner** ←

Theorie Beispiel

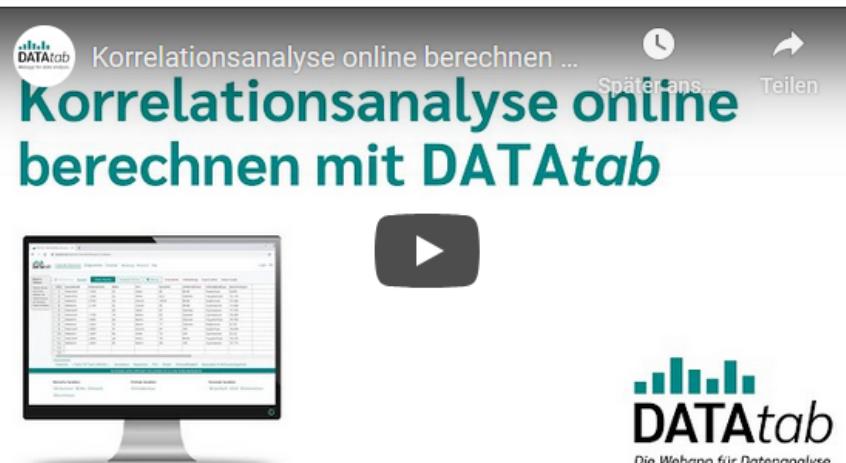
Korrelationsanalyse

Mithilfe von **Korrelationsanalysen** kann der lineare Zusammenhang von Variablen untersucht werden, weshalb diese auch als **Zusammenhangsanalysen** bezeichnet werden. Wie stark die **Korrelation** ist, ergibt sich über den **Korrelationskoeffizienten**, der von -1 bis +1 schwankt. Damit kann mit der Korrelationsanalysen eine Aussage über die Stärke und die Richtung des Zusammenhangs gemacht werden.

Korrelationsanalyse online berechnen ...

Korrelationsanalyse online berechnen mit DATAtab

DATAtab Die Webapp für Datenanalyse.



.. bis zum nächsten

