


# de Wageningse Methode



correlatie en  
regressie

## Inhoudsopgave

Waarom is dit boek	1
Wat is de bedoeling van dit boek	4
Wat is de structuur	5
Wat is de inhoud van de hoofdstukken	7
Wat is de opbouw van de hoofdstukken	9
Wat is de opbouw van de hoofdstukken	10
Wat is de opbouw van de hoofdstukken	12
Wat is de opbouw van de hoofdstukken	20
Wat is de opbouw van de hoofdstukken	22
Wat is de opbouw van de hoofdstukken	23
Wat is de opbouw van de hoofdstukken	24
Wat is de opbouw van de hoofdstukken	27
Wat is de opbouw van de hoofdstukken	28
Wat is de opbouw van de hoofdstukken	32
Wat is de opbouw van de hoofdstukken	34
Wat is de opbouw van de hoofdstukken	36
Wat is de opbouw van de hoofdstukken	37
Wat is de opbouw van de hoofdstukken	39
Wat is de opbouw van de hoofdstukken	40
Wat is de opbouw van de hoofdstukken	41
Wat is de opbouw van de hoofdstukken	42
Wat is de opbouw van de hoofdstukken	43
Wat is de opbouw van de hoofdstukken	45
Wat is de opbouw van de hoofdstukken	46
Wat is de opbouw van de hoofdstukken	49
Wat is de opbouw van de hoofdstukken	53
Wat is de opbouw van de hoofdstukken	56

Dit is een boek van de Nederlandse Vereniging voor de Wetenschap.

Auteurs: Jan van der Vliet, Wim Kremers, Jan Smit, Gerard Stroomer, Stef Tijds.

Verkoopadres: Postbus 105, 6860 AC Oosterbeek.

Verkoopadres: Postbus 105, 6860 AC Oosterbeek.

Dit boek is vervaardigd door middel van druk, fotokopie, microfilm of op welke andere wijze ook vervaardigd door de auteurs van het copyright.



## Wat is er aan de hand?

Wat is de belangrijkste reden dat kinderen met een autisme spectrumstoornis (AS) moeite hebben met het begrijpen van de gevoelens van anderen? Het is belangrijk om te weten dat kinderen met AS vaak moeite hebben met het begrijpen van de gevoelens van anderen. Dit kan worden veroorzaakt door een verschil in de manier waarop ze informatie verwerken. Ze kunnen bijvoorbeeld moeite hebben met het begrijpen van de context van een situatie of met het herkennen van gezichtsuitdrukkingen.

De belangrijkste reden dat kinderen met een autisme spectrumstoornis (AS) moeite hebben met het begrijpen van de gevoelens van anderen is dat ze vaak moeite hebben met het begrijpen van de context van een situatie. Dit kan worden veroorzaakt door een verschil in de manier waarop ze informatie verwerken. Ze kunnen bijvoorbeeld moeite hebben met het begrijpen van de context van een situatie of met het herkennen van gezichtsuitdrukkingen.

De belangrijkste reden dat kinderen met een autisme spectrumstoornis (AS) moeite hebben met het begrijpen van de gevoelens van anderen is dat ze vaak moeite hebben met het begrijpen van de context van een situatie. Dit kan worden veroorzaakt door een verschil in de manier waarop ze informatie verwerken. Ze kunnen bijvoorbeeld moeite hebben met het begrijpen van de context van een situatie of met het herkennen van gezichtsuitdrukkingen.

Wat zijn de belangrijkste kenmerken van autisme spectrumstoornis (AS)?

Wat zijn de belangrijkste kenmerken van autisme spectrumstoornis (AS)?

Wat zijn de belangrijkste kenmerken van autisme spectrumstoornis (AS)?

Wat zijn de belangrijkste kenmerken van autisme spectrumstoornis (AS)?

Wat zijn de belangrijkste kenmerken van autisme spectrumstoornis (AS)?

Wat zijn de belangrijkste kenmerken van autisme spectrumstoornis (AS)?

Wat zijn de belangrijkste kenmerken van autisme spectrumstoornis (AS)?

	AS	NW	
AS	a	b	34
NW	c	d	68
	27		102

	AS	NW	
AS	a	b	34
NW	c	d	68
	27		102

--	--	--	--




Zwak verband

	W	NW	
M	28	6	34
NM	47	21	68
	75	27	102

Zou je het verband tussen W en M in de tabel positief of negatief noemen? Waarom?

Geef zelf ook een invulling van de tabel waarbij er sprake is van een zwak verband. Zorg er daarbij voor dat het juist in de andere richting wijst dan bij de tabel daarboven.

	W	NW	
M			34
NM			68
	75	27	102



## positief of negatief verband

**WM 1**

10.30 s de  
11.00 solli-  
12.00 une  
dion!  
nde:  
A-  
mé  
25  
ort  
r

10.00 Teletekst  
10.15 Zondag op 2: met V  
ner takes all; 10.25 Cham  
on the wonderhorse; 10.  
Popeye and son; 11.20 Bit  
Peter Omnibus; 11.50 Bos  
Cat; 12.15 Boxpops.  
13.00  Anne of windy po  
plars - Amerikaanse film uit  
1940 met Anne Shirley e.a.  
14.25 Darts - het w.k. in Frimley  
Green.  
15.15 a a a  
17.10 Music in camera - Tokyo  
string quartet speelt Schubert.  
18.00 Rugby special  
18.55 Ski sunday  
19.35 The money programme  
20.15 Atlantic Realm (1) -  
Island Arks. Driedelige docu-  
mentaire over de geschiede-  
nis en natuurlijke ontwikkeling  
van de Atlantische Oceaan  
Voornamelijk

Bij een kijkonderzoek wordt aan n mensen ge-  
vraagd of ze de tv programma's A en/of B de  
afgelopen week gezien hebben.  
De resultaten van de enquête worden in een  
2 x 2 - tabel weergegeven. (Hierin is NA de groep  
die programma A niet gezien heeft.)

	A	NA	
B	a	b	
NB	c	d	
			= n

Vul, uitgaande van de randgetallen in de tabel, de  
getallen a, b, c en d, de  
randgetallen in de tabel, de  
getal c aan? Wat geeft het  
getal b+d aan? Wat geeft het

Er is een positief verband tussen A en B voor  
wat het kijkgedrag van de ondervraagden betreft  
als binnen de A-groep de verhouding B : NB  
hoger ligt dan binnen de NA-groep.

Leid hieruit af:  
er is een positief verband als  $ad - bc > 0$ .  
Op dezelfde manier kun je afleiden:  
er is een negatief verband als  $ad - bc < 0$  en  
er is geen verband als  $ad - bc = 0$ .

Geef bij elk van de tabel-  
verband er tussen A en B bestaat.

	A	NA
B	183	249
NB	654	453

	A	NA
B	345	678
NB	764	876

Kies twee programma's die in de afgelopen week  
zijn uitgezonden en waarbij je een positief of  
juist een negatief verband verwacht.  
Onderzoek of je vermoeden in je klas uitkomt.

en, weten we of  
of of een nega-

er afhangt van  
et afhangt van  
wordt  $ad - bc$   
product van de  
en  $a+b$ .

associatie, de  
 $2 \times 2$  - tabel

B	A	NA	
NB	a	b	$a + b$
	c	d	$c + d$
	$a + c$	$b + d$	n

R

ssende woord

ciatiemaat R.

	W	
M	25	NW
NM	50	9
		18

R = \_\_\_\_\_ verband

	W	NW
M	34	0
NM	41	27

\_\_\_\_\_ verband

R = \_\_\_\_\_

	W	
M	7	NW
NM	68	27
		0

R = \_\_\_\_\_ verband

	W	NW
M	28	6
NM	47	21

\_\_\_\_\_ verband

R = \_\_\_\_\_

# associatie

Bereken R ook hiernaast. voor de acht 2 x 2 - tabelletjes

2	3
3	2

3	2
2	3

20	30
30	20

21	14
14	21

R = \_\_\_\_ R = \_\_\_\_ R = \_\_\_\_ R = \_\_\_\_

1	4
4	1

5	0
0	5

0	5
3	0

2	1
3	0

R = \_\_\_\_ R = \_\_\_\_ R = \_\_\_\_ R = \_\_\_\_

Wat valt je op bij de eerste vier tabelletjes?

De associatie van de tabel hiernaast is 0. Vul de ontbrekende getallen in.

	7	
20	10	

R = 0

De associatie van de linkertabel is 1, die van de rechtertabel -1. Vul de ontbrekende getallen in.

20	10

R = 1

20	10

R = -1

Als je geen fouten maakte, vond je voor R steeds een uitkomst die tussen -1 en 1 ligt. R kan ook nog gelijk aan -1 of aan 1 zijn. R is nooit kleiner dan -1 of groter dan 1.

Als R = 1, welke twee getallen (a, b, c of d) zijn dan 0? En welke twee als R = -1?



Ro	
	13
6	52

	PI	NPI
Aa		
NAa		
		52

R = \_\_\_\_\_

o	
5	52

	Ha	NHa
Aa		
NAa		
		52

R = \_\_\_\_\_



# onafhankelijkheid en kansen

Iemand trekt een kaart uit een volledig spel.

Hoe groot is  $P(Ha)$ , de kans op een harten? Hoe groot is  $P(Pl)$ , de kans op een plaatje? Bereken ook  $P(Ha \text{ èn } Pl)$ , de kans op een harten plaatje.

--	--	--

Welk verband bestaat er tussen deze drie kansen?

--

Vul langs de rand van de tabel de drie nog ontbrekende kansen in. Vul ook in de vakjes de passende kansen in.

	Ha	NHa	
Pl			$P(Pl) = \frac{4}{13}$
NPl			$\frac{9}{13}$
	$P(Ha) =$		

In de kansrekening heten twee gebeurtenissen A en B **onafhankelijk** als  $P(A \text{ èn } B) = P(A) \cdot P(B)$ .

Een school heeft 1000 leerlingen, 700 in de onderbouw en 300 in de bovenbouw. Van deze 1000 leerlingen zijn er 100 linkshandig, de rest is rechtshandig.

	Lh	Rh	
Ob			700
Bb			300
	100	900	1000

Neem aan dat er geen verband is tussen deze twee incidenten. Vul in de vakjes de te verwachten aantallen in.

Aselect wordt één leerling gekozen. Vul in het schema hiernaast de passende kansen in. Neem aan dat de verdeling precies is zoals je bij 'geen verband' verwacht.

	Lh	Rh	
Ob			$P(Ob) =$
Bb			
			1

De overeenkomst tussen de twee tabellen is duidelijk!

## toevallige verbanden



Helma trekt zes kaarten uit een volledig spel en let op het aantal harten en het aantal plaatjes.

Stel dat zij trekt: harten 7, ruiten boer, schoppen vrouw, schoppen 4, klaveren 8 en klaveren 9.

Vul de  $2 \times 2$  - tabel in en bereken  $R$ .

Hoe groot zou  $R$  geweest zijn als zij twee harten plaatjes, twee andere plaatjes en twee niet-harten niet-plaatjes getrokken had?

Geef een tabel waarbij  $R = 1$ . Geef ook een tabel waarbij  $R = -1$  en een tabel waarbij  $R = 0$ .

Zoals je ziet kan  $R$  bij zo'n trekking van zes kaarten allerlei waarden aannemen, waarden die van het toeval afhangen.

Soms kan  $R$  zelfs niet berekend worden. Geef een verdeling waarbij  $R$  onbepaald is.

Hoe groot is  $R$  voor het volledige kaartspel?

*Uit het bovenstaande blijkt dat een steekproef toevallig de indruk kan wekken dat er een verband is tussen twee dingen, terwijl dat verband er in de populatie zelf helemaal niet is. Vooral bij kleine steekproeven spelen zulke toevalseffecten een rol.*

*Hoe groter de som  $n$  van de getallen  $a$ ,  $b$ ,  $c$  en  $d$  in de vier vakjes, hoe kleiner de toevalseffecten.*

### Vuistregel:

Als er geen verband is, krijg je maar zelden een  $R$  die meer dan  $\frac{2}{\sqrt{n}}$  van 0 afwijkt en bijna nooit een  $R$  die meer dan  $\frac{3}{\sqrt{n}}$  van 0 afwijkt. Als je toch zo'n waarde vindt, mag je aannemen dat er verband is (of dat de steekproef niet aselekt is!).

	Ha	Nha
PI		
NPI		

$R = \underline{\hspace{2cm}}$


$R = \underline{\hspace{2cm}}$


$R = 1$


$R = -1$


$R = 0$


$R$  is onbepaald

--

## aspirine en hartinfarct

In januari 1987 stond dit bericht in de krant. Lees het even.

### Aspirinegebruik verlaagt kans op hartinfarct met 45%

ROTTERDAM, 28 jan — Het om de dag innemen van een aspirientje verlaagt het risico op een hartinfarct bijna tot de helft. Dat is de conclusie van een grootschalig Amerikaans onderzoek dat vandaag in het medische vaktijdschrift *New England Journal of Medicine* is gepubliceerd.

Bij het onderzoek, dat in 1982 begon, waren ruim 22.000 gezonde, mannelijke artsen betrokken (mannen hebben een ongeveer 2 maal zo hoog risico op een hartinfarct als vrouwen). De helft daarvan gebruikte om de dag 300 milligram aspirine, wat ongeveer gelijkstaat aan een „gewoon” aspirientje. De andere helft slikte een placebo („fopmiddel”). Van de aspirine-slikkers kregen 104 een hartinfarct, van de placebo-slikkers 189.

Door het aspirinegebruik werd

het risico op een hartinfarct dus met ongeveer 45 procent verlaagd. Dat dit grote verschil aan toeval te wijten zou zijn is praktisch uitgesloten, vanwege het grote aantal mensen dat aan de studie meewerkte. Deze werking van het aspirine berust waarschijnlijk op het tegengaan van bloedklontering op de vaatwanden.

Hart- en vaatziekten vormen in de meeste Westerse landen de belangrijkste doodsoorzaak. Men verwacht dan ook dat het onderzoeksresultaat grote gevolgen zal kunnen hebben voor de preventie van hartinfarcten.

Verheugt: „Het is pas de eerste studie. Binnenkort verschijnt er een Engelse studie met een soortgelijke resultaat, maar met een minder dramatisch verschil”.

Waarom werkt men bij zo'n onderzoek met fop-pillen?

Geef de resultaten in een 2 x 2 - tabel en bereken de associatiemaat R.

	Aspirine	Placebo	
Hartinf			
Geen inf			
	11 000	11 000	22 000

R = \_\_\_\_\_

In de steekproef zijn de aantallen hartinfarcten bij „Aspirine” en „Placebo” nogal verschillend. Wat denk je, is dit verschil toevallig? Gebruik de vuistregel van de vorige bladzijde.

# artinfarct

mogelijkheid om te bekijken  
zou kunnen zijn.

zijn, dus wanneer aspirinege-  
nebben, dan kunnen we de  
dcten beschouwen als een  
e populatie van 22 000 art-

steekproef zonder terugleggen.  
steekproef toch beschouwen  
?

zont van de steekproef zal,  
u zijn, uit aspirineslikkers

29 onderzoeken kunnen we  
13 keer opgooien van een  
kop, noem dat  $X$ , kan ook  
van de helft!


Wat zijn de waarden van de  
deling?

kt 104 van  $E(X)$  af, m.a.w.  
104 ?

op deze afwijking of een  
is?

chil tussen de aantallen

de associatiegraad  $R$  van



De...  
 De...  
 De...

De...  
 De...

	1	2	3	4	5
1	12	13			
2	45	74			
3	8				
4	10	42	40		

De...  
 De...

De...  
 De...

De...  
 De...

De...  
 De...

De...  
 De...

De...  
 De...

De...  
 De...

De...  
 De...

# bij veel

De...  
 De...

De...  
 De...

De...  
 De...

De...  
 De...

De...  
 De...

De...  
 De...

De...  
 De...

De...  
 De...

De...  
 De...

De...  
 De...

De...  
 De...

De...  
 De...

De...  
 De...

De...  
 De...

De...  
 De...

De...  
 De...

De...  
 De...

De...  
 De...

De...  
 De...

De...  
 De...

De...  
 De...

De...  
 De...

De...  
 De...


De...  
 De...

De...  
 De...


De...  
 De...

De...  
 De...

De...  
 De...



	$x < 70$	$x \geq 70$	
$y \geq 60$			
$y < 60$			
			13 R = _____



\_\_\_\_\_ verband

R = \_\_\_\_\_



Het zal duidelijk zijn dat we er niet alleen op moeten letten in welke hoek de punten liggen. We zullen er ook naar moeten kijken hoe ver de punten in de hoeken liggen, hoe ze ten opzichte van elkaar liggen. Spreiding speelt immers ook een rol.

We bekijken eerst de spreiding in de x- en y-waarden apart.

Als maat voor de spreiding gebruiken we de y-standaardafwijking. De standaardafwijking is de wortel uit de variantie. De SD is

In boekje 52 - normale verdeling zagen we op bladzijde 2 de volgende twee formules voor de variantie van de getallen  $x_1, x_2, \dots, x_n$  van een tabestand:

Eerste formule voor de variantie:

$$\text{Var}(x_1, x_2, \dots, x_n) = \frac{1}{n} \cdot ((x_1 - \bar{x})^2 + (x_2 - \bar{x})^2 + \dots + (x_n - \bar{x})^2)$$

In woorden: de variantie is de gemiddelde kwadratische afwijking.

Voorbeeld: het gemiddelde van 2, 6, 6 en 8 is 5,5 en dus is de variantie

$$\frac{1}{4} \cdot (3,5^2 + 0,5^2 + 0,5^2 + 2,5^2) = \frac{1}{4} \cdot (12,25 + 0,25 + 0,25 + 6,25) = 4,75 \quad \text{SD}(x) = \sqrt{4,75} = 2,18.$$


Tweede formule voor de variantie:

$$\text{Var}(x_1, x_2, \dots, x_n) = \frac{1}{n} \cdot (x_1^2 + x_2^2 + \dots + x_n^2) - \bar{x}^2$$

In woorden: de variantie is het gemiddelde van de kwadraten min het kwadraat van het gemiddelde.

Voorbeeld: het gemiddelde van 2, 6, 6 en 8 is 5,5 en dus is de variantie

$$\frac{1}{4} \cdot (2^2 + 6^2 + 6^2 + 8^2) - 5,5^2 = \frac{1}{4} \cdot (4 + 36 + 36 + 64) - 30,25 = 35 - 30,25 = 4,75 \quad \text{SD}(x) = \sqrt{4,75} = 2,18.$$



De resultaten van de

i	1	2	3	4	5	
A	$x_i$	62	70	83	61	90
B	$y_i$	45	65	55	72	75

	6	7	8	9	10	11	12	13
	55	76	80	85	53	80	45	74
	36	48	70	68	62	80	42	40

Bereken het gemiddelde van de x-waarden. Gebruik je rekenmachine?

Bereken ook het gemiddelde van de y-waarden. Gebruik je rekenmachine?

Nu gaan we de waarden combineren tot  $(x_i - \bar{x})$  en  $(y_i - \bar{y})$ . Door te letten op de x- en y-producten wordt de zogenaamde covariantie berekend.

Met behulp van deze producten wordt de zogenaamde covariantie berekend.

Eerste formule voor de covariantie

$$\text{Cov}(x,y) = \frac{1}{n} \cdot ((x_1 - \bar{x})(y_1 - \bar{y}) + (x_2 - \bar{x})(y_2 - \bar{y}) + \dots + (x_n - \bar{x})(y_n - \bar{y}))$$

In woorden: de covariantie is het gemiddelde product van de afwijkingen.

Tweede formule voor de covariantie

$$\text{Cov}(x,y) = \frac{1}{n} \cdot (x_1 \cdot y_1 + x_2 \cdot y_2 + \dots + x_n \cdot y_n) - \bar{x} \cdot \bar{y}$$

In woorden: de covariantie is het gemiddelde van de producten min het product van de gemiddelden.

Welk voordeel heeft de tweede formule?

Waar zijn we zeker van?


# Waar veel bij veel

intelligentietest waarden:	1	2	3	4	5
1	12	13			
2	45	74			
3	42	40			



# van 2 bij 2 naar veel bij veel

ernaast is bij een puntenwolk ook het punt  $(\bar{x}, \bar{y})$  aangegeven. De horizontale en de verticale stiplijn door  $(\bar{x}, \bar{y})$  verdelen het gebied waarin de puntenwolk ligt in vier gebieden.



welke gebieden liggen de punten die een positieve bijdrage leveren aan de covariantie? Aan welke formule kun je dat het best zien?


welke gebieden liggen de punten die een negatieve bijdrage leveren aan de covariantie?

welke gebieden leveren de punten die op een oppellijn liggen aan de covariantie?


Wat denk je, is de covariantie bij de punten van de puntenwolk op blz. 12 positief of negatief?

Waarom? Bereken de covariantie van de punten  $(x_i, y_i)$  uit de puntenwolk op blz. 12. Gebruik je rekenmachientje.


Bereken bij elk van de vier puntenwolken hieronder de covariantie.




Cov = \_\_\_\_\_



Cov = \_\_\_\_\_ 5



Cov = \_\_\_\_\_



Cov = \_\_\_\_\_ 5

## van 2 bij 2 naar veel bij veel

De covariantie is een maat voor de samenhang tussen de x- en y-waarden, maar nog niet zo'n beste!

Wat gebeurt er met  $\text{Cov}(x,y)$  als alle x-waarden met 10 vermenigvuldigd worden? En als alle y-waarden door 12 gedeeld worden?

Een maat voor de samenhang die niet afhangt van de eenheden waarin x en y gemeten worden, is de **correlatiecoëfficiënt**.

Die vind je door de covariantie te delen door de standaarddeviatie van x en die van y.





De correlatiecoëfficiënt wordt meestal aangegeven met de letter r.

### Eerste formule voor de correlatiecoëfficiënt

$$r = \frac{\text{Cov}(x,y)}{\text{SD}(x) \cdot \text{SD}(y)}$$

Bereken de correlatiecoëfficiënt r van de dertien punten van de intelligentietest.

Bereken bij elk van de vier puntenwolken hiernaast de correlatiecoëfficiënt r. Op de vorige bladzijde heb je de covariantie al berekend!



## Bij 2 naar veel bij veel

de formule voor r ook zo geschreven

$$r = \frac{1}{n} \sum_{i=1}^n \frac{(x_i - \bar{x}) \cdot (y_i - \bar{y})}{SD(x) \cdot SD(y)}$$

waarde van  $x_i$ , de afwijking van  $x_i$  gemeten in standaardafwijkingen.

Formule voor de correlatiecoëfficiënt


$$r = \frac{1}{n} \sum_{i=1}^n z(x_i) \cdot z(y_i)$$

de  $\frac{x_i - \bar{x}}{SD(x)}$  de z-waarde van  $x_i$  is,

de correlatiecoëfficiënt is het gemiddelde van de producten van de z-waarden van  $x_i$  en  $y_i$ .

Uit de tabel blijkt Harrie, Tieme, Ton en Walter de beste springers. Bij het verspringen respectievelijk de plaatsen 1, 2, 3 en 4. Bij het hoogspringen de plaatsen 2, 1, 3 en 4.

	$x_i$	$y_i$
Harrie	1	2
Tieme	2	1
Ton	3	3
Walter	4	4



Geef de punten van deze resultaten nog eens tekenen.

Geef de punten  $(x_i, y_i)$  in het rooster aan. Schrijf bij elke letter van de naam van de bijbehorende springer.

Bereken het verband tussen  $x$  en  $y$  positief of negatief?

Bereken de correlatiecoëfficiënt  $r$  van deze vier punten.



Laat z-waarden deken worden

$$z = \frac{x - \bar{x}}{SD(x)}$$

Merk op dat  $\frac{x_i - \bar{x}}{SD(x)}$

$SD(x)$  is de

van

Gevolg

Tweede

$$z = \frac{x_i - \bar{x}}{SD(x)}$$

waarbij  $z(x_i)$

In woorden is de

Op een spel

Walter bezette

en 4, 1, 2

en 4, 1, 3

In de tabel

rug.

Geef de

elke stip

rende st

Wat der

of negat

tief?

Bereken

ten.


## Van 2 bij 2 naar veel bij veel

We nemen bij het hoogspringen een andere uitslag:

	$x_i$	$y_i$
Harrie	1	4
Tieme	2	3
Ton	3	1
Walter	4	2

Teken het hierbij behorende puntendiagram.

Wat is nu het verband tussen  $x$  en  $y$ , positief of negatief?



We houden steeds dezelfde uitslag bij het verspringen.





Op hoeveel verschillende manieren kunnen er rangnummers voor het hoogspringen aan gekoppeld worden?

Er is één manier waarbij  $r = 1$ . Teken het puntendiagram dat daar bij hoort.







Er is één manier waarbij  $r = -1$ . Teken het puntendiagram dat daar bij hoort.

Er zijn twee manieren waarbij  $r = 0$ . Teken de twee diagrammen die daar bij horen.

Als het je niet lukt, kijk dan nog eens naar de eerste formule voor de covariantie. En niet te snel opgeven!

Bereken bij elk van de zes puntenwolken hier-  
naast de correlatiecoëfficiënt  $r$ .



Bij het berekenen van  $r$  vind je altijd een uit-  
komst die tussen  $-1$  en  $+1$  ligt.  
In extra sterk komen we daar op terug.

De correlatiecoëfficiënt is alleen dan  $1$  als de  
punten op een rechte lijn liggen met positieve  
richtingscoëfficiënt.

De correlatiecoëfficiënt is alleen dan  $-1$  als de  
punten op een rechte lijn liggen met negatieve  
richtingscoëfficiënt.



# Rangnummers

De naam **correlatiecoëfficiënt** spreekt men wel van de rangnummers. Hij is vernoemd naar de psycholoog Charles Spearman. Deze methode is in het begin van de 20e eeuw ontwikkeld.

In de psychologie komt het vaak voor dat men een ranglijst heeft en een andere ranglijst. Het is niet met een getal voorkeur bijvoorbeeld, maar met een getal kan aangegeven hoe groot de voorkeur is. Het werkt met rangnummers dan uitkomst.

Als we twee reeksen punten  $(x_i, y_i)$  hebben en alle x-waarden en alle y-waarden verschillend zijn, dan kunnen we de rangnummers  $a_i$  van 1 tot n toekennen en de rangnummers  $b_i$  van 1 tot n toekennen aan de y-waarden. Bereken  $\bar{a}$  en  $\bar{b}$ .

Met welke formule vind je  $Var(a) = \frac{1}{12} \cdot (n^2 - 1)$  de volgende formule worden afgeleid:

correlatiecoëfficiënt van de rangnummers:

$$r(a,b) = \frac{1}{n} - \frac{6}{n(n^2 - 1)} \cdot ((a_1 - b_1)^2 + (a_2 - b_2)^2 + \dots + (a_n - b_n)^2)$$

Aan de welke deze formule kan je eenvoudig zien dat de twee volgorden moet gelijk aan 1 zijn. Welke voorwaarden moeten er zijn?

Bereken de correlatiecoëfficiënt met deze formule nog eens de rangcorrelatiecoëfficiënt  $r(a,b)$  bij de dertien punten van de vorige bladzijde.

Bereken de correlatiecoëfficiënt bij de tabel van het springen op blz. 17. Ook nog eens met de formule.

--	--

--

--

--

## met tabelletjes werken?

In dit boekje moet je nogal ingewikkelde formules. Als welke formule je wilt gebruiken, bleem rekenfouten te voorkomen. Dat kun je berekenen door het rekenwerk te maken.

Tabelletjes kunnen je daarbij helpen; tabelletjes die je moet aanpassen aan de formule die je gebruikt.

### Voorbeeld:

Bij een wolk van punten  $(x_i, y_i)$  wordt de correlatiecoëfficiënt  $r$  te berekenen.

Neem aan dat je wilt werken met de volgende formule:

$$r = \frac{\frac{1}{n} \cdot (x_1 \cdot y_1 + x_2 \cdot y_2 + \dots + x_n \cdot y_n) - \bar{x} \cdot \bar{y}}{SD(x) \cdot SD(y)}$$

Het is dan handig om te werken als hiernaast.

Vul die tabel verder in en bereken  $r(x, y)$ .

Natuurlijk had je ook zó te werken kunnen gaan:

- Op je rekenmachientje voer je de  $x$ -waarden in en lees je  $\bar{x}$  en  $SD(x)$  af. Die uitkomsten noteer je.
- Op je rekenmachientje voer je de  $y$ -waarden in en lees je  $\bar{y}$  en  $SD(y)$  af. Die uitkomsten noteer je.
- Je berekent  $\bar{x} \cdot \bar{y}$  en noteert de uitkomst.
- Op je rekenmachientje voer je de  $x \cdot y$ -waarden in en lees je het gemiddelde daarvan af. Ook die uitkomst noteer je.
- Je berekent nu  $\frac{1}{n} \cdot (x_1 \cdot y_1 + \dots + x_n \cdot y_n) - \bar{x} \cdot \bar{y}$ .
- Je berekent  $r(x, y)$ .

Bereken ook op deze tweede manier  $r(x, y)$ . Hierbij is het van groot belang dat je alle tussenresultaten opschrijft. Het is zaak je berekeningen overzichtelijk te houden!

$x_i$	$y_i$	$x_i^2$	$y_i^2$	$x_i \cdot y_i$
2,7	4,5			
1,5	1,9			
5,2	9,1			
3,9	6,3			
6,1	11,7			
19,4	33,5			

$n =$  \_\_\_\_\_

$\bar{x} =$  \_\_\_\_\_  $\bar{x}^2 =$  \_\_\_\_\_  $\bar{y} =$  \_\_\_\_\_  $\bar{y}^2 =$  \_\_\_\_\_

$Var(x) = \bar{x}^2 - (\bar{x})^2 =$  \_\_\_\_\_



$Var(y) = \bar{y}^2 - (\bar{y})^2 =$  \_\_\_\_\_

$SD(x) \cdot SD(y) =$  \_\_\_\_\_  $\bar{x} \cdot \bar{y} =$  \_\_\_\_\_

$\frac{1}{n} \cdot (x_1 \cdot y_1 + \dots + x_n \cdot y_n) =$  \_\_\_\_\_

$\frac{1}{n} \cdot (x_1 \cdot y_1 + \dots + x_n \cdot y_n) - \bar{x} \cdot \bar{y} =$  \_\_\_\_\_

$r(x, y) =$  \_\_\_\_\_









## van de vierde naar de vijfde klas

In het schooljaar 1986-87 begonnen 78 leerlingen uit vwo 4 van het Liemers College in vwo 5 met Wiskunde A. Met Pasen zijn hun rapportcijfers voor wiskunde A vergeleken met hun cijfers voor wiskunde een jaar eerder in vwo 4.

De resultaten zie je hiernaast in een x,y-tabel. Horizontaal x, het cijfer voor wiskunde op het baasrapport in vwo 4; verticaal y, het cijfer voor wiskunde A een jaar later in vwo 5.

(vijfde klas)

y	2	10	33	22	10	1	
9				1			1
8				3	3	1	7
7		1	5	8	5		19
6		5	20	7			32
5	2	4	6	2	1		15
4			2	1	1		4
	4	5	6	7	8	9	


x (vierde klas)

hoeveel leerlingen hebben hetzelfde cijfer op hun rapport gehouden?

hoeveel leerlingen zijn er vooruit gegaan? Wat was het vaakst voor: vooruit gaan of achteruit gaan?

Wat is het grootste aantal punten dat een leerling achteruit is gegaan?

(vijfde klas)



x (vierde klas)

Bereken  $\bar{x}$ ,  $\text{Var}(x)$  en  $\text{SD}(x)$ . Gebruik je rekenmachine.

## van de vierde naar de vijfde

klas

Bij hoeveel leerlingen wijkt de  $x$ -waarde meer dan  $2SD(x)$  van  $\bar{x}$  af? Is dat in overeenstemming met de vuistregel die hiervoor geldt?

Bereken  $\bar{y}$ ,  $Var(y)$  en  $SD(y)$ .

Ga met een berekening na dat  $Cov(x,y) = 0,4722$ .

Bereken de correlatiecoëfficiënt  $r(x,y)$ .

We kunnen bij elke leerling ook kijken naar het aantal punten  $d$  dat hij of zij vooruit is gegaan:  $d = y - x$ .

Vul de tabel verder in.

verschil	$d$	2	1	0	-1	-2	-3	-4
frequentie	$f$	2						1
	$d \cdot f$							
	$d^2 \cdot f$							

Bereken het gemiddelde verschil  $d$ .

Welk verband bestaat er tussen  $\bar{d}$ ,  $\bar{x}$  en  $\bar{y}$ ?

Bereken  $Var(d)$  en  $SD(d)$  met behulp van de gegevens uit de tabel.

Waarom geldt zeker niet:  $Var(d) = Var(x) - Var(y)$ ?

Waarom geldt ook niet:  $Var(d) = Var(x) + Var(y)$ ?

Toch mag je een zeker verband verwachten tussen  $Var(d)$ , de spreiding van de verschillen en de correlatie tussen  $x$  en  $y$ .

Ga na dat in dit geval geldt:  
 $2 \cdot Cov(x,y) = Var(x) + Var(y) - Var(d)$ .

Neem even aan: alle leerlingen zijn één punt vooruit gegaan.

Hoe groot zijn dan  $Var(d)$  en  $r(x,y)$ ?

## naar de vijfde klas

Alger  
 schill  
 en, des te kleiner is  
 Bewi  
 het v  
 is de volgende for  
 erband precies is.

de spreiding in de ver-  
 nul  
 e. Daarin zie je hoe

$$\text{Var}(d) = \text{Var}(y-x) = \text{Var}(y) + \text{Var}(x) - 2 \cdot \text{Cov}(x,y)$$

Bij ee  
 kend: n verzameling punt  
 en

Var(x) = 169, Var(y) = 225  
 Berek en Cov(x,y) en r(x,y).  
 (x,y) heeft men bere-  
 en Var(y-x) = 134.

Uit di  
 mule  
 leid: e formule hierbove  
 voor de correlatiecoë

kan de volgende for-  
 fficiënt worden afge-

Derd  
 e formule voor de

correlatiecoëfficiënt

$$r(x,y) = \frac{\text{Cov}(x,y)}{\sqrt{\text{Var}(x) \cdot \text{Var}(y)}} \text{ waarbij } d = y - x$$

Hoe  
 aan  
 latie  
 leid je, met behul  
 de bladzijde, de der  
 coëfficiënt af?

van de formule boven  
 formule voor de corre-

Vijf  
 proef  
 fers:  
 leerlingen hebben  
 v  
 werken voor Wisk  
 un

voor twee opvolgende  
 de A de volgende cij-

eerst  
 te proefwerk  $x_i$  7,3  
 twee  
 de proefwerk  $y_i$  6,3

8,9	4,3	5,9	6,8
9,1	5,7	6,5	6,0

Bere  
 ken Var(x), Var(y),  
 Var

(d) en r(x,y).



# In de associatie en

van bij een middelbare school  
 de cijfer altijd een z  
 andere leraar op d  
 zevens en achten.

Bereken tabel zie je de cijfer  
 beide leraren les he

Bereken

Bereken

Bereken en de associatiema

Wat vinden ook  $\bar{x}$ ,  $\bar{y}$  en  $\bar{d}$  =

Met behulp van  $\text{Var}(x)$ ,  $\text{Var}(y)$  en

bewezen de correlatiecoëf

correlatiecoëficienten  
 alt je op als je R m

Daar kun alleen behulp van de algem

en worden dat de a  
 tiecoëfficiënt  $r$  alti

komt echter nogal w  
 voor de echte lieff

	cijfer x		
6	7		
7	18	12	30
8	17	3	20
	35	15	50


	cijfer x		
	$x_1$	$x_2$	
$y_1$	a	b	$a + b$
$y_2$	c	d	$c + d$
	$a + c$	$b + d$	n

## toevallige correlatie



Aan drie toevallige voorbijgangers A, B en C, wordt hun leeftijd  $x$  en hun huisnummer  $y$  gevraagd. Het resultaat zie je in de tabel hiernaast.

	$x$	$y$
A	42	55
B	16	38
C	55	89

Bereken  $\bar{x}$ ,  $\bar{y}$  en  $\bar{d} = \bar{y} - \bar{x}$ .

Bereken  $\text{Var}(x)$ ,  $\text{Var}(y)$  en  $\text{Var}(d)$ .

Reken na:  $r(x,y) = \frac{13}{14} = 0,93\dots$

We mogen aannemen dat er in de populatie waaruit de steekproef genomen is geen enkel verband bestaat tussen leeftijd en huisnummer. Hoe kun je de grote waarde van  $r$  toch verklaren?

Op hoeveel manieren kun je drie  $x$ -waarden, bijvoorbeeld 16, 42 en 55, en drie  $y$ -waarden, bijvoorbeeld 38, 55 en 89, combineren tot drie punten  $(x,y)$ ?

Als er geen verband is tussen  $x$  en  $y$ , dan zou elk van deze mogelijkheden dezelfde kans hebben. In het overzicht hiernaast zie je alle mogelijkheden. Bij elk van die mogelijkheden is de correlatiecoëfficiënt  $r$  berekend.







--	--	--

--	--	--

--

--

--



ken ook  $\text{Var}(r)$ .

veel mogelijke punten  $(x,y)$  zijn er als we niet  
ie maar bij  $n$  personen een  $x$  en een  $y$  geno-  
hebben? Neem aan dat er geen verband  
en  $x$  en  $y$  bestaat en dat alle  $x$ -waarden en  
 $y$  waarden verschillend zijn.

veel mogelijkheden zijn er als er twee  $x$ - en  
 $y$ -waarden gelijk zijn?

meen:

n aselecte steekproef van  $n$  personen wordt  
der een  $x$  en een  $y$  genoteerd.

in de populatie waaruit de steekproef komt  
enkel verband is tussen  $x$  en  $y$ , dan zijn alle  
eren waarop de  $x$ -waarden aan de  $y$ -waar-  
gekoppeld kunnen worden even waarschijn-

le  $x$ - en alle  $y$ -waarden verschillend zijn,  
ijn er  $n!$  mogelijkheden om die waarden te  
en tot een wolk van  $n$  punten.

van deze  $n!$  puntenwolken kan de correla-  
fficiënt  $r$  berekend worden.

eldt:

middelde van deze correlatiecoëfficiënten  
ies 0 en  
andaardafwijking van deze  $r$ -waarden is  
an  $1/\sqrt{(n-1)}$ .

an groot belang voor de beoordelen van  
iecoëfficiënten. De volgende opgaven  
dat toe.

# toevallige correlatie

Neem aan dat er in werkelijkheid geen verband is tussen de  $x$ - en de  $y$ -waarden, gevonden in een steekproef van tien personen.

Bereken de standaardafwijking in de bijbehorende  $r$ -waarden.



Kun je verklaren waarom een correlatiecoëfficiënt van 0,35 tussen de  $x$ - en de  $y$ -waarden best kan optreden maar dat  $r = 0,7$  onwaarschijnlijk is?

Laat zien dat een correlatiecoëfficiënt van 0,35 zeer onwaarschijnlijk is als de steekproef wordt uitgebreid tot honderd personen.

Ga na dat de formule voor de standaardafwijking juist is als  $n = 2$ .



We vervangen de  $x$ -waarden  $x_1, x_2, \dots, x_n$  door de rangnummers 1, 2, ...,  $n$ . Met de  $y$ -waarden doen we hetzelfde.

Hiernaast zijn bij  $n = 5$  twee mogelijke puntenwolken getekend.



Hoeveel van deze puntenwolken zijn er mogelijk?

Teken een puntenwolk waarvan de correlatiecoëfficiënt 0 is. Ook één waarbij  $r = 1$ .



Hoe groot is de kans om toevallig  $r = 1$  te krijgen?







Hoe groot (ongeveer) is bij  $n = 7$  de kans dat je een puntenwolk krijgt waarvan de correlatiecoëfficiënt 0 is?

Hoe groot is de standaardafwijking bij  $n = 7$  ?

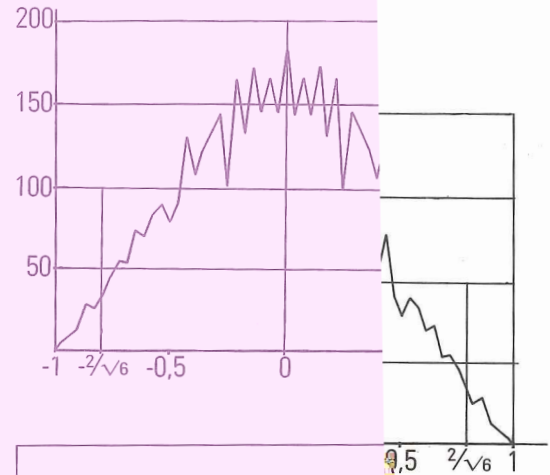
Hoe groot is zo ongeveer de kans dat je een  $r$ -waarde vindt die meer dan twee keer de standaardafwijking van 0 af ligt?

Tip: Let op de oppervlakte onder de grafiek. Gebruik een stukje vierkantjespapier.

lijk

en-  
er-

frequentie



0,5  $2/\sqrt{6}$  1



# en toeval

Uit het competitieoverzicht (zie ook boekje 48 - bino-  
 gecoord. g) kun je halen hoeveel doelpunten  
 thuis- en in zijn uitwedstrijden heeft

	doelpunten	
	thuis	uit
1 SC Cambuur	x	y
2 Eindhoven		
3 Graafschaap	27	22
4 FC den Haag	35	17
5 Heerenveen	24	31
6 Heracles	21	28
7 MVV	27	20
8 NAC	32	16
9 NEC	39	33
10 RBC	48	24
11 SVV	25	22
12 Telstar	29	16
13 FC Twente	16	20
14 Veendam	25	27
15 Vitesse	49	33
16 FC VVV	22	21
17 Wageningen	38	14
	37	17
	23	19

Maak de punt

enwolk hiernaast af.


Wat denk je,  
 verband tusse

is er positief of een negatief  
 en x en y ?

de Volkskrant van MAANDAG 14 MEI 1984

THUIS	UIT																
	SC CAMBUUR	EINDHOVEN	GRAAFSCHAP	FC DEN HAAG	HEERENVEEN	HERACLES	MVV	NAC	NEC	RBC	SVV	TELSTAR	FC TWENTE	VEENDAM	VITESSE	FC VVV	WAGENINGEN
SC CAMBUUR		3-1	1-1	1-2	2-0	1-1	1-1	0-0	1-1	2-0	4-2	2-3	1-1	3-2	1-1	3-3	1-0
EINDHOVEN	0-0		0-5	2-5	2-2	2-0	1-3	6-4	0-2	0-2	4-1	3-1	1-3	3-2	3-1	4-1	4-3
GRAAFSCHAP	3-0	2-1		2-1	0-0	2-1	2-2	6-2	0-2	2-1	1-0	0-1	0-2	2-2	1-1	0-1	1-1
FC DEN HAAG	0-1	4-0	1-3		0-3	3-0	0-0	0-1	3-1	2-1	1-0	2-1	2-4	2-0	1-0	0-1	0-1
HEERENVEEN	2-4	3-0	2-3	1-1		0-2	0-0	0-4	1-3	2-1	1-1	1-0	0-3	3-3	6-3	2-1	2-2
HERACLES	0-0	2-2	2-3	2-2	1-0		0-0	4-1	5-2	6-1	1-1	1-5	1-2	0-0	3-2	2-0	2-1
MVV	1-1	3-2	2-2	1-0	3-2	3-1		1-4	4-1	3-2	4-1	1-1	2-1	1-0	0-1	4-1	6-0
NAC	3-1	4-2	3-2	1-0	1-0	2-1	4-4		2-0	2-1	5-2	2-3	3-0	10-1	2-1	0-0	4-1
NEC	1-3	2-1	0-1	1-2	3-1	2-0	0-1	2-0		1-0	2-1	1-0	5-2	2-2	2-0	1-2	0-0
RBC	0-2	4-1	5-2	4-1	2-2	1-1	0-2	3-0	1-1		2-1	2-2	0-2	3-0	0-1	1-1	1-3
SVV	0-3	3-1	3-1	1-3	0-2	0-3	2-5	1-1	0-2	1-1		1-2	0-1	0-3	1-1	3-2	0-1
TELSTAR	1-0	1-0	1-1	1-3	5-1	1-1	1-1	0-1	3-2	2-1	4-1		0-2	1-1	2-1	2-0	1-1
FC TWENTE	3-2	7-1	2-2	2-0	2-1	1-1	1-2	2-1	3-1	1-1	3-4	5-0		5-0	2-1	7-0	
VEENDAM	2-3	1-1	1-2	0-4	1-2	1-2	2-3	1-1	0-2	3-2	2-2	2-1	2-4		1-1	3-2	0-5
VITESSE	1-1	5-3	2-0	1-1	4-2	2-1	1-4	0-2	3-1	3-1	5-3	3-1	1-3	3-2		1-0	3-0
FC VVV	0-2	3-1	3-2	1-2	5-1	3-1	1-5	2-1	2-1	3-1	2-1	1-1	4-2	1-2	2-0		4-0
WAGENINGEN	1-0	0-0	1-1	1-1	1-1	3-0	1-0	2-1	0-0	5-0	2-2	1-1	1-1	2-1	0-0	2-1	

## Eerste divisie



# en toeval

De machijentje is nagegaan:  
De x-waarden = 517  
De y-waarden = 380  
De  $x_2$ -waarden = 17123  
De  $y_2$ -waarden = 9084  
De xy-waarden = 11698

De hulp van deze uitkomsten:

$Cov(x,y)$  en  $r(x,y)$ .

De berekeningen op.

De relatiecoëfficiënt op verband tus-  
sicht je en antwoord toe.

De maat van FC Twente weg en bepaal  
de efficiëntie van de 16 overblijvende  
pountenwolk.

De antwoord op de voorlaatste vraag?

Var(x):

Var(y):

Cov(x,y):

r(x,y):

vrienden


**VEN 1986**

type	deuren	zit- plaatsen	f	per dag 24 uur	per km
personenwagens					
opel Corsa *	2	4	f	26,00	0,23
opel Kadett *	2	4	f	30,00	0,26
opel Record *	4	4/5	f	42,00	0,40

154 km

Id) als je  
n hebt.

grafieken.





## Das richtige Verhalten

Beim Einsteigen muss je nach der  
Tafel, dem Kopf und dem Körper  
die richtige Haltung eingenommen  
werden.

Beim Aussteigen muss je nach der  
Tafel, dem Kopf und dem Körper  
die richtige Haltung eingenommen  
werden.

Beim Einsteigen muss je nach der  
Tafel, dem Kopf und dem Körper  
die richtige Haltung eingenommen  
werden.

Beim Aussteigen muss je nach der  
Tafel, dem Kopf und dem Körper  
die richtige Haltung eingenommen  
werden.

Es ist eine wichtige Aufgabe der  
Lehrer, die Schüler zu einem  
richtigen Verhalten zu erziehen.  
Dies geschieht durch die  
Eingabe von Beispielen und  
durch die Erörterung von  
Sachverhalten.

Die Schüler müssen lernen, die  
richtige Haltung einzunehmen.  
Dies geschieht durch die  
Eingabe von Beispielen und  
durch die Erörterung von  
Sachverhalten.

Die Schüler müssen lernen, die  
richtige Haltung einzunehmen.  
Dies geschieht durch die  
Eingabe von Beispielen und  
durch die Erörterung von  
Sachverhalten.



# de lijn van de gemiddelden

Op bladzijde 24, 25 en 26 hebben we bij 78 leerlingen het verband onderzocht tussen het cijfer  $x$  voor wiskunde op het paarsrapport in vwo-4 en het cijfer  $y$  voor wiskunde A in vwo-5 van dezelfde leerling een jaar later.

Er was duidelijk correlatie:  $r = 0,46$ . Bij een hogere  $x$  vind je gemiddeld ook een hogere  $y$ -waarde.

Deze trend kunnen we ook nog op een andere manier laten zien. We berekenen bij elke waarde van  $x$  het gemiddelde  $\bar{y}(x)$  van de daarbij behorende  $y$ -waarden.

Ga na dat de eerste twee waarden van  $\bar{y}(x)$  in de tabel juist zijn en vul de tabel daarna verder in.

Geef de punten uit de tabel aan in de figuur hier naast. In die figuur is het "zwaartepunt van de puntenwolk"  $(\bar{x}, \bar{y}) = (6,40; 6,17)$  al aangegeven.

Ook deze puntenwolk maakt de tendens duidelijk: bij hogere  $x$  gemiddeld ook een hogere  $y$ .

Teken door het punt  $(6,40; 6,17)$  een rechte lijn die zo ongeveer deze trend weergeeft. Bedenk daarbij dat sommige gemiddelden maar op een paar leerlingen berusten.

Hoe groot is ongeveer de richtingscoëfficiënt van de lijn die je getekend hebt?


(vijfde klas)

y	2	10	33	22	10	1	
9				1			
8				3	3	1	1
7		1	5	8	5		7
6		5	20	7			19
5	2	4	6	2	1		32
4			2	1	1		15
	4	5	6	7	8	9	4

x (vierde klas)

e klas)

x	4	5	6	7	8	
$\bar{y}(x)$	5,00	5,70				9



bedacht om een lijn te berekenen die "zo goed mogelijk" de stijgende of dalende trend van de gemiddelden weergeeft. Die lijn wordt de regressielijn genoemd. (Zie ook extra en zo maar kijken we nog eens, op een andere manier deze lijn.)

### Eerste formule voor de regressielijn

$$\frac{y - \bar{y}}{SD(y)} = r \cdot \frac{x - \bar{x}}{SD(x)}$$

### Tweede formule voor de regressielijn

$$y = r \cdot \frac{SD(y)}{SD(x)} \cdot x - r \cdot \frac{SD(y)}{SD(x)} \cdot \bar{x} + \bar{y} \rightarrow z_y = r \cdot z_x$$

Merk op:

de regressielijn gaat door het zwaartepunt van de puntenwolk (het gemiddelde van de richtingscoëfficiënt hangt af van de richtingscoëfficiënt en SD(y));

bij positieve r is de regressielijn stijgend, bij negatieve r is de regressielijn dalend.

Ga na hoe de tweede formule, de formule voor de regressielijn, uit de eerste volgt.

Bereken de formule voor de regressielijn die hoort bij de puntenwolk van de wiskunde in de klas (zie bladzijde 24, 25 en 26).

Komt de richtingscoëfficiënt van de regressielijn die je zo berekent op het oog tekende op de vorige bladzijde overeen met de richtingscoëfficiënt die je zo berekent op de vorige bladzijde?

die je zo berekent op het oog tekende op de vorige bladzijde overeen met de richtingscoëfficiënt die je zo berekent op de vorige bladzijde?




standaardafwijkingen SD(x)

ter), bij negatieve r is de

correlatiecoëfficiënt r (en van de s

cent (x̄, ȳ) van de puntenwolk

lijn van y op x

van y op x

sterk, daar  
manier naar

nd van de

zo goed

en zo maar

gemiddelden

de stijgende of dalende

bedacht om een lijn te berekenen die

In het algemeen worden statistische gegevens vaak gebruikt om voorspellingen te doen. Ook de regressielijn kan daarvoor gebruikt worden.

Als je bijvoorbeeld het cijfer  $x$  van een leerling uit de vierde klas weet kun je met de formule van de regressielijn:  $y = 0,480x + 3,094$  een voorspelling doen voor het cijfer  $y$  dat deze leerling in de vijfde zal hebben.

Welk cijfer voorspel je op deze manier voor een leerling die in de vierde een 4 had?

Laat zien dat bij een positieve correlatiecoëfficiënt een  $x$  die boven het gemiddelde ligt, een voorspelling  $y$  geeft die ook boven het gemiddelde ligt. Gebruik de eerste formule voor de regressielijn:

$$\frac{y - \bar{y}}{SD(y)} = r \cdot \frac{x - \bar{x}}{SD(x)}$$

Waarom zal (in standaardafwijkingen uitgedrukt) de afwijking  $y - \bar{y}$  kleiner zijn dan  $x - \bar{x}$ ?

Aan deze laatste eigenschap dankt de regressielijn zijn naam: regressie: teruggaan, terugvallen. Hier naar het midden, het gemiddelde.




## no. 11. (10 punten)

Hierbij staat nog eens de tabel met de kosten  $y$  (in gulden) van een receptie van een aantal gasten  $x$  (in reacties) op een bruiloft.

gasten $x$	70	110	145	175	205	265
kosten $y$	325	440	575	615	712	820

Hierbij is de bijbehorende puntenwolk getekend.



Bereken met je rekenmachine

- de som van de  $x$ -waarden = \_\_\_\_\_
- de som van de  $y$ -waarden = \_\_\_\_\_
- de som van de  $x^2$ -waarden = \_\_\_\_\_
- de som van de  $y^2$ -waarden = \_\_\_\_\_
- de som van de  $xy$ -waarden = \_\_\_\_\_

Bereken met deze gegevens  $\bar{x}$  en  $\bar{y}$ .

Bereken ook de richtingscoëfficiënt  $a$  van de regressielijn.

Geef in de puntenwolk het zwaartepunt aan. Teken de regressielijn.

Geef ook een vergelijking van deze lijn.

Welk aantal reacties mag je verwachten op een advertentie die 900 gulden kost?

En hoeveel reacties mag je verwachten op een advertentie die 2000 gulden kost?

Welke van deze laatste twee voorspellingen is het meest betrouwbaar? Waarom?

## en zoon

De hiernaast is gebruikt als omslag voor een boek over statistiek dat in 1978 in de Verenigde Staten is verschenen.

Een puntenwolk (Engels: scatterdiagram) bestaat uit punten  $(x,y)$ , waarbij  $x$  de lengte van een vader is en  $y$  de lengte van diens volwassen zoon. De puntenwolk is het resultaat zijn van een onderzoek dat in 1869 in Leeds in 1900 in Engeland werd gehouden. Francis Galton interesseerde zich toen voor de overerving van bepaalde eigenschappen. Francis Galton (1822-1911) was een van de pioniers op dat gebied. Het onderzoek waar het hier om gaat is gepubliceerd in 1903 door Pearson en Lee. Het boek van Galton, een bekend wetenschappelijk tijdschrift, bestaat nu nog bestaat.

Op de hiernaast vind je de volgende informatie over de puntenwolk op de omslag:  
De gemiddelde lengte van de vaders, is 68 inch  
De standaarddeviatie is 2,7 inch.  
De gemiddelde lengte van de zoons, is 69 inch  
De standaarddeviatie is 2,7 inch.  
De correlatiecoëfficiënt  $r$  is 0,5.

Gebruik de gegevens om naar centimeters, 1 inch = 2,54 cm. Rond de gemiddelde lengten af op een heel getal en de SD's op een getal met maximaal één komma.

Gebruik de vergelijking van de regressielijn.

Gebruik de plaatje in verticale stroken van bij elkaar 10 en een halve centimeter en schat in een minuut het gemiddelde van de  $y$ -waarden. Gebruik de strook het gemiddelde van de  $y$ -waarden en plak een stip aan.

Gebruik de twee lijnen in de puntenwolk is de vergelijking van de regressielijn?

Gebruik de regressiecoëfficiënt van de andere lijn?

Gebruik de vergelijking van de hand geweest zijn als alle andere lijn gelegen hadden?



$\bar{x} =$ _____ cm	$\bar{y} =$ _____ cm
$SD(x) =$ _____ cm	$SD(y) =$ _____ cm

Om een eenvoudiger plaatje te krijgen is de omslag de schaalverdeling langs de assen op de gelaten. Die schaalverdeling willen we ten weg-rugvin-

In welk punt van de puntenwolk zullen, r mag aannemen, de twee lijnen elkaar snijden? Hoe zijn de x- en de y-waarden verdeeld?

Breng je verdeling (in cm) op de assen aan.

Schat, met behulp van de regressielijn, de lengte van de zoon van een vader die 180 cm lang is.

Je kunt ook de vraag stellen: Hoe groot is de vader als je de lengte van de zoon weet? We moeten dan kijken naar horizontale lijnen. Bij een gegeven y-waarde kijken we naar de gemiddelde van de bijbehorende x-waarden het

Verdeel de puntenwolk in een stuk of tien horizontale stroken. Schat bij elke strook de gemiddelde x-waarden. Geef dat gemiddelde gemiddelde gemiddelde stip aan. in het

Teken de lijn die het best past bij je tien stippen.

Deze tweede lijn van gemiddelden noemt men de regressielijn van x op y (de andere lijn is de regressielijn van y op x). Deze lijn geeft dan de gemiddelde x-waarde bij een gegeven y-waarde.

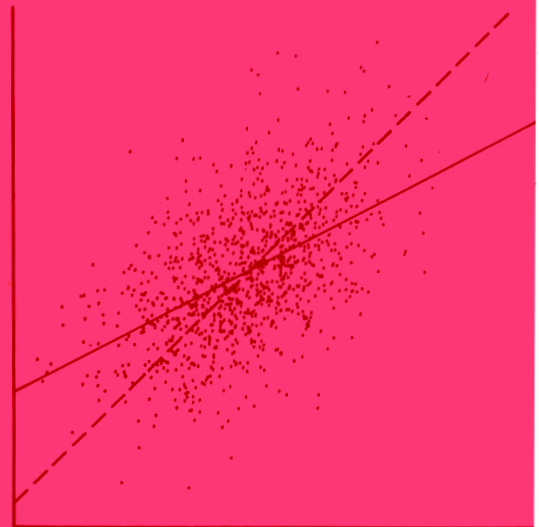
Een algemene formule voor deze lijn is:

$$\frac{x - \bar{x}}{SD(x)} = r \cdot \frac{y - \bar{y}}{SD(y)} \text{ ofwel } \frac{y - \bar{y}}{SD(y)} = \frac{1}{r} \cdot \frac{x - \bar{x}}{SD(x)}$$

Geef een vergelijking van de regressielijn bij de 'vader-en-zoon-gegevens'. gres-

Schat, met behulp van deze vergelijking, de lengte van de vader van een zoon die 180 cm lang is.





## e en onafhankelijke variabelen

verband tussen gewicht en  
bij Nederlanders van ongeveer  
het meer zin te kijken naar hoe  
gewicht verandert met de lengte  
Vaarom is dat zo?

an gewicht  $y$  op lengte  $x$  geeft  
van wat ongeveer het normale  
i bepaalde lengte.  
hier de lengte, noemt men de  
riabele; die kan niet beïnvloed  
re variabele, hier het gewicht,  
ankelijke variabele.

variabele geeft men meestal  
r  $x$ , de afhankelijke variabele

tijd is er zo'n duidelijk verschil  
variabelen als bij gewicht en  
je bijvoorbeeld van de lengte  $x$   
de lengte  $y$  van de vrouw bij  
erland?

ordt bijgehouden hoeveel  
tie oplevert. Een overzicht van  
een advertentie en het aantal  
de tabel op bladzijde 23.


ankelijke en wat is de onafhan-

rdt een product gemaakt. De  
en de productiekosten worden

inkelijke en wat is de onafhan-

orbeeld waarbij het ook niet  
geven welke de afhankelijke  
ankelijke variabele is.





## groei

Een bioloog onderzoekt de groei van zonnebloemen. Hij denkt te kunnen bewijzen dat in een bepaalde fase van de groei de hoogte  $h$  van zo'n bloem exponentieel van de tijd  $t$  afhangt:

$$h = H \cdot g^t.$$

In die fase verzamelt hij de volgende gegevens:

$t$ (in dagen)	0	4,8	11,5	16,2	22,6	30,7
$h$ (in cm)	72	85	108	142	190	256

Teken hiernaast de volk van de punten  $(t_i, y_i)$ , waarbij  $y_i = \log(h_i)$ .

Mag je, zo op het oog, een juiste veronderstelling maken dat de bioloog een juiste veronderstelling maakte? Waarom?

Bereken de correlatiecoëfficiënt  $r(t, y)$ .

Geef een vergelijking van de regressielijn die hoort bij de punten  $(t_i, y_i)$ . Schrijf die vergelijking in de vorm  $y = a \cdot t + b$ .

Teken de regressielijn.

Geef met behulp van de constanten  $a$  en  $b$  een formule voor de hoogte  $h$  als functie van de tijd.

de groei van zonnebloemen. Hij denkt te kunnen bewijzen dat in een bepaalde fase van de groei de hoogte  $h$  van zo'n bloem exponentieel van de tijd  $t$  afhangt:

hij de volgende gegevens:


volk van de punten  $(t_i, y_i)$ ,

aannemen dat de bioloog een juiste veronderstelling maakte? Waarom?

coëfficiënt  $r(t, y)$ .

van de regressielijn die hoort bij de punten  $(t_i, y_i)$ . Schrijf die vergelijking in de vorm  $y = a \cdot t + b$ .

de constanten  $a$  en  $b$  een formule voor de hoogte  $h$  als functie van de tijd.








# Wettelijke belangen

en verbouwt aardappelen en graan,  
se aardappelen en suikerbieten.  
en van deze twee landbouwers komt  
meer de helft uit de aardappelen. Een  
engst en prijs van de aardappelen is  
voor beiden.  
k is er een duidelijke correlatie tus-  
msten van de twee boeren.

ijke samenhang kunnen we eenvoudig  
met dobbelstenen.

en geven  $X_1$ ,  $X_2$  en  $X_3$  ogen.

$$X_1 + X_2 \text{ en } Y = X_1 + X_3.$$

meenschappelijke term  $X_1$  zijn  $X$  en  $Y$   
onafhankelijk.

ren van 2 tot (en met) 12,  $Y$  ook. Maar  
combinaties, bijvoorbeeld  $X = 3$  en  
niet mogelijk.

in het punt (3, 9) niet optreden?

een paar combinaties die niet kunnen  
geef ook aan waarom ze niet kunnen

manieren kan het punt (4,5) optreden.  
mogelijkheden op.

alle mogelijkheden op voor het punt

atje op de volgende bladzijde zie je  
ten  $(x,y)$  kunnen optreden en op hoe-  
ren.

et gemiddelde van de  $y$ -waarden bij  
bij  $x = 12$ .





# Relangen

Je kunt uit deze populatie ook een steekproef nemen, bijvoorbeeld door twintig keer twee dobbelstenen te gooien. De kans dat je een 12 krijgt zal een correlatiecoëfficiënt van  $r = 1/2$  waarschijnlijk niet precies  $1/2$  is. Als je een grotere steekproef neemt, dan zal de correlatiecoëfficiënt daarvan steeds meer de correlatiecoëfficiënt van de populatie benaderen.

### Opmerking 2.

We kunnen het gemeenschappelijk deel van  $X$  en  $Y$  groter of kleiner maken.

Je gooit vier keer met een dobbelsteen.

$X = X_1 + X_2 + X_3$  en  $Y = X_1 + X_2$

Het gemeenschappelijk deel is dan  $2/4$  en stelt: correlatiecoëfficiënt is dan  $1/2$ .

Kun je verklaren waarom de regressie gegeven wordt door de formule:  $y = 2/3 \cdot x$

Je gooit vijf keer met een dobbelsteen.

$X = X_1 + X_2 + X_3$  en  $Y = X_3 + X_4$

Het gemeenschappelijk deel is dan  $1/5$  en stelt:

Hoe groot is, denk je, de correlatiecoëfficiënt?

Wat is nu een vergelijking van de regressie?

### Opmerking 3.

De correlatiecoëfficiënt  $r = 1/2$  bij de vader en zoon (blz. 40) is in het licht van dit wel aannemelijk. Waarom?

steekproef  
met drie  
die je  
die  
echter een  
relatie-  
lijken op

de  
deel  
van X en  
een

den stelt:  
in  $g/4$ .

roter, de  
sielij  
 $1/3 \cdot x$

n nu ge-  
een:  $+ 3 1/2$  ?

den stelt:  
klei  $K_5$ .

de coëfficiënt nu?


ssielijn?

de ler  
dit  
ngtes van  
voorbeeld






zelftoets





Mathematics

Discontinuity

Continuity

Discontinuity

Continuity

Discontinuity

Continuity

Discontinuity

Continuity

Discontinuity

Continuity

Discontinuity

Continuity

Discontinuity

Continuity

Discontinuity

Continuity

Discontinuity

Continuity

Discontinuity

Continuity

Discontinuity

Continuity

## aantekeningen/samenvatting

Nog meer formules:

Eerste formule voor de regressielijn (van y op x)

$$\frac{y - \bar{y}}{SD(y)} = r \cdot \frac{x - \bar{x}}{SD(x)}$$

vorm  $y = ax + b$

$$a = r \cdot \frac{SD(y)}{SD(x)} = \frac{cov(x, y)}{SD(x)^2}$$

door  $(\bar{x}, \bar{y})$

Tweede formule voor de regressielijn

$$y = r \cdot \frac{SD(y)}{SD(x)} \cdot x - r \cdot \frac{SD(y)}{SD(x)} \cdot \bar{x} + \bar{y}$$

ofwel

$$y = a \cdot x + b \text{ met } a = r \cdot \frac{SD(y)}{SD(x)} \text{ en } b \text{ zó dat } (\bar{x}, \bar{y}) \text{ op de regressielijn ligt.}$$

Formule voor de regressielijn van x op y

$$\frac{x - \bar{x}}{SD(x)} = r \cdot \frac{y - \bar{y}}{SD(y)} \text{ ofwel}$$

$$\frac{y - \bar{y}}{SD(y)} = \frac{1}{r} \cdot \frac{x - \bar{x}}{SD(x)}$$

vorm  $y = ax + b$

$$a = \frac{1}{r} \cdot \frac{SD(y)}{SD(x)} = \frac{SD(y)}{cov(x, y)}$$

door  $(\bar{x}, \bar{y})$

deur van de

deur van de

deur van de

deur van de

deur van de

deur van de

Charakteristiek

De aanvrager wordt  
geïnterviewd door  
de recruiter van  
de organisatie.

De aanvrager wordt geïnterviewd door de recruiter van de organisatie. Het interview kan telefonisch of persoonlijk plaatsvinden. Het interview kan ook worden gevolgd door een test of een proefwerk.

De aanvrager wordt geïnterviewd door de recruiter van de organisatie.

De aanvrager wordt geïnterviewd door de recruiter van de organisatie. Het interview kan telefonisch of persoonlijk plaatsvinden. Het interview kan ook worden gevolgd door een test of een proefwerk.

De aanvrager wordt geïnterviewd door de recruiter van de organisatie.

De aanvrager wordt geïnterviewd door de recruiter van de organisatie. Het interview kan telefonisch of persoonlijk plaatsvinden. Het interview kan ook worden gevolgd door een test of een proefwerk.

De aanvrager wordt geïnterviewd door de recruiter van de organisatie. Het interview kan telefonisch of persoonlijk plaatsvinden. Het interview kan ook worden gevolgd door een test of een proefwerk.

De aanvrager wordt geïnterviewd door de recruiter van de organisatie. Het interview kan telefonisch of persoonlijk plaatsvinden. Het interview kan ook worden gevolgd door een test of een proefwerk.

De aanvrager wordt geïnterviewd door de recruiter van de organisatie. Het interview kan telefonisch of persoonlijk plaatsvinden. Het interview kan ook worden gevolgd door een test of een proefwerk.

De aanvrager wordt geïnterviewd door de recruiter van de organisatie.

De aanvrager wordt geïnterviewd door de recruiter van de organisatie.

De aanvrager wordt geïnterviewd door de recruiter van de organisatie.

De aanvrager wordt geïnterviewd door de recruiter van de organisatie. Het interview kan telefonisch of persoonlijk plaatsvinden. Het interview kan ook worden gevolgd door een test of een proefwerk.

De aanvrager wordt geïnterviewd door de recruiter van de organisatie. Het interview kan telefonisch of persoonlijk plaatsvinden. Het interview kan ook worden gevolgd door een test of een proefwerk.

De aanvrager wordt geïnterviewd door de recruiter van de organisatie.

De aanvrager wordt geïnterviewd door de recruiter van de organisatie. Het interview kan telefonisch of persoonlijk plaatsvinden. Het interview kan ook worden gevolgd door een test of een proefwerk.

De aanvrager wordt geïnterviewd door de recruiter van de organisatie. Het interview kan telefonisch of persoonlijk plaatsvinden. Het interview kan ook worden gevolgd door een test of een proefwerk.

De aanvrager wordt geïnterviewd door de recruiter van de organisatie. Het interview kan telefonisch of persoonlijk plaatsvinden. Het interview kan ook worden gevolgd door een test of een proefwerk.

De aanvrager wordt geïnterviewd door de recruiter van de organisatie.

De aanvrager wordt geïnterviewd door de recruiter van de organisatie. Het interview kan telefonisch of persoonlijk plaatsvinden. Het interview kan ook worden gevolgd door een test of een proefwerk.

gelopen jaar  
ven.

ingenomen,

itanten is  
wen heeft

ken krijgt  
nan koers

de aanvil-

banen en

vacatures

illicitanten  
procent

bij beter

relatief

die wer-

hoger  
groe-

gelijk.

daar de

man

vrouw

W

aangenomen

afgewezen

laag betaald

aangenomen

afgewezen

beter betaald

aangenomen

afgewezen

man

vrouw

man

vrouw

300

100

400

## krekels


In de zomer kun je 's avonds vaak krekels horen sjirpen. De frequentie waarmee ze dat doen, is afhankelijk van de temperatuur. Van de gestreepte veldkrekel heeft George W. Pierce, professor aan de Harvard University, met behulp van speciaal ontwikkelde apparatuur een gedetailleerde studie gemaakt.

Een deel van zijn bevindingen vind je in de tabel hieronder. Hiernaast staat het bijbehorende spreidingsdiagram.

In de tabel en het diagram is  $x$  de frequentie (aantal sjirpen per seconde) en  $y$  de temperatuur (in graden Fahrenheit).

Gemakshalve staan de waarden van  $xy$  ook in de tabel.

$x$	$y$	$xy$
20,0	88,6	1772,0
16,0	71,6	1145,6
19,8	93,3	1847,3
18,4	84,3	1551,1
17,1	80,6	1378,3
15,5	75,2	1165,6
14,7	69,7	1024,6
17,1	82,0	1402,2
15,4	69,4	1068,8
16,2	83,3	1349,5
15,0	79,6	1194,0
17,2	82,6	1420,7
16,0	80,6	1289,6
17,0	83,5	1419,5
14,4	76,3	1098,7

Temperature ( $^{\circ}$ F)

Rond bij de eerste drie vragen de uitkomsten van je berekeningen af op drie cijfers na de komma.



## extra werk

Bereken  $\bar{x}$ ,  $\bar{y}$ ,  $SD(x)$  en  $SD(y)$ .

--	--	--	--

Bereken de correlatiecoëfficiënt  $r$ .

--

Geef een vergelijking van de regressielijn (van  $y$  op  $x$ ). Rond de parameters af op één cijfer na de komma.

--

Teken deze regressielijn in het spreidingsdiagram.

Een krekel sjirpt 19,0 keer per seconde. Schat de temperatuur met behulp van je formule van de regressielijn.

--

Het verband tussen de temperatuur in graden Celsius ( $c$ ) en in graden Fahrenheit ( $y$ ) wordt gegeven door:  $c = \frac{5}{9} \cdot (y - 32)$ .

Stel een vergelijking op van de regressielijn waarbij de temperatuur niet in graden Fahrenheit maar in graden Celsius is gegeven.

--

Toon aan dat de correlatiecoëfficiënt bij gebruik van de Celsiuschaal even groot is als bij gebruik van de Fahrenheitchaal.

--

Hoe groot is de correlatiecoëfficiënt van  $x$  op  $y$ ?

--

Geef ook een vergelijking van de regressielijn van  $x$  op  $y$ . Rond de parameters af op één cijfer na de komma.

--

Teken ook de regressielijn van  $x$  op  $y$  in het spreidingsdiagram.

Hoe vaak schat je dat een gestreepte veldkrekel per seconde sjirpt bij een temperatuur van 85,0 graden Fahrenheit? Gebruik je formule voor de regressielijn van  $x$  op  $y$ .

--

Welke frequentie had je gevonden als je je formule voor de regressielijn van  $y$  op  $x$  gebruikt had?

--



## extra sterk

Ga na hoe uit de twee formules voor de variantie volgt:

$$(z_1 - \bar{z})^2 + \dots + (z_n - \bar{z})^2 = z_1^2 + \dots + z_n^2 - n \cdot \bar{z}^2$$

Gevolg:

$$z_1^2 + \dots + z_n^2 = (z_1 - \bar{z})^2 + \dots + (z_n - \bar{z})^2 + n \cdot \bar{z}^2$$

Stel:  $z_i = x_i - t$ .

Laat zien:  $\bar{z} = \bar{x} - t$  en  $z_i - \bar{z} = x_i - \bar{x}$ .

Toon nu aan:

$$Q(t) = (x_1 - t)^2 + \dots + (x_n - t)^2$$

$$= (x_1 - \bar{x})^2 + \dots + (x_n - \bar{x})^2 + n(\bar{x} - t)^2$$

Hieruit volgt direct:  $Q$  is minimaal als  $t = \bar{x}$ .  
Hoe (precies) ?

**die Punkte  $A_1$  und  $A_2$  inkomplex gerad**

Wskanz, die 70 Punkte  $A_1, A_2, \dots, A_{10}$  in  
 reiner Anordnung. Aber bei diesen Punkten  
 sind diese Punkte angeordnet. Die sind diese  
 Punkte in einem bestimmten 2-fachigen Anordnungs-  
 nach der Anzahl der Punkte.

Die Punkte sind inkomplex 1, die 70  
 Punkte sind inkomplex 1, die 70  
 Punkte sind inkomplex 1, die 70  
 Punkte sind inkomplex 1, die 70

Die Punkte sind inkomplex 1, die 70  
 Punkte sind inkomplex 1, die 70  
 Punkte sind inkomplex 1, die 70  
 Punkte sind inkomplex 1, die 70

Die Punkte sind inkomplex 1, die 70  
 Punkte sind inkomplex 1, die 70  
 Punkte sind inkomplex 1, die 70  
 Punkte sind inkomplex 1, die 70

Die Punkte sind inkomplex 1, die 70  
 Punkte sind inkomplex 1, die 70  
 Punkte sind inkomplex 1, die 70  
 Punkte sind inkomplex 1, die 70

Die Punkte sind inkomplex 1, die 70  
 Punkte sind inkomplex 1, die 70  
 Punkte sind inkomplex 1, die 70  
 Punkte sind inkomplex 1, die 70

Die Punkte sind inkomplex 1, die 70  
 Punkte sind inkomplex 1, die 70  
 Punkte sind inkomplex 1, die 70  
 Punkte sind inkomplex 1, die 70


Die Punkte sind inkomplex 1, die 70  
 Punkte sind inkomplex 1, die 70  
 Punkte sind inkomplex 1, die 70  
 Punkte sind inkomplex 1, die 70

Die Punkte sind inkomplex 1, die 70  
 Punkte sind inkomplex 1, die 70  
 Punkte sind inkomplex 1, die 70  
 Punkte sind inkomplex 1, die 70

Die Punkte sind inkomplex 1, die 70  
 Punkte sind inkomplex 1, die 70  
 Punkte sind inkomplex 1, die 70  
 Punkte sind inkomplex 1, die 70

$$A_1A_2 - A_3 - A_4 + \dots + A_{10} - A_{11}$$

Die Punkte sind inkomplex 1, die 70  
 Punkte sind inkomplex 1, die 70  
 Punkte sind inkomplex 1, die 70  
 Punkte sind inkomplex 1, die 70



\_\_\_\_\_

\_\_\_\_\_

\_\_\_\_\_

\_\_\_\_\_

\_\_\_\_\_

\_\_\_\_\_



\_\_\_\_\_

\_\_\_\_\_

\_\_\_\_\_

\_\_\_\_\_

\_\_\_\_\_



$$y = ax + b$$

x

y



De gemiddelde waarde

De standaarddeviatie

De gemiddelde waarde

De standaarddeviatie

De gemiddelde waarde

De standaarddeviatie

De gemiddelde waarde

De gemiddelde waarde

De standaarddeviatie

De gemiddelde waarde

De standaarddeviatie

De gemiddelde waarde

De standaarddeviatie

De gemiddelde waarde

De standaarddeviatie

De gemiddelde waarde

$$n(\bar{y} - a\bar{x} - b)^2$$

$$(x_i - \bar{x})(y_i - \bar{y}) + \sum_{i=1}^n (y_i - \bar{y})^2 + n(\bar{y} - a\bar{x} - b)^2$$

$$= \text{Var}(y) + n(\bar{y} - a\bar{x} - b)^2$$

a, b) gelijk is aan:

$$\text{Var}(y) + n(\bar{y} - a\bar{x} - b)^2$$

De eerste term is 0 wordt?

De tweede term is 0 wordt?

De lijn  $y = ax + b$  gaat door het zwaartepunt  $(\bar{x}, \bar{y})$ .

dat

De correlatiecoëfficiënt

alle punten liggen op een lijn?

Is het omgekeerde van de regressie lijn? (omgekeerde regressie)