

STICHTING  
MATHEMATISCH CENTRUM  
2e BOERHAAVESTRAAT 49  
AMSTERDAM  
STATISTISCHE AFDeling

S 4

Dantzig, D. van, Theil, H.

Eerste verslag betreffende groeiproeven met Wistar-ratten.

1948



Den Heer Thomassen  
Unilever Laboratorie  
ZWIJNDRECHT.

Geachte Heer Thomassen,

Naar aanleiding van ons gesprek van heden kan ik U nog het volgende mededelen.

Laat gegeven zijn de  $E_x$  waarden  $x_1, \dots, x_n$   
"  $E_{y_{j+1}}$  "  $y_1, \dots, y_n$

$N$  is het aantal groepen ( $\approx 24$ )

Elke  $x_j$  resp.  $y_j$  is het groepsgemiddelde van één groep van  $\frac{1}{12}$  dieren en heeft een spreiding  $\frac{\sigma}{\sqrt{n}}$  ( $n = 12$ ), waarin  $\sigma$  de spreiding in de gewichtstoename per dier is (alles gedurende een bepaalde week). Ook de spreiding van elke  $y_j$  is  $= \frac{\sigma}{\sqrt{n}}$  aangenomen; de correlatiecoefficient van elke  $x_j$  met de  $y_j$  van dezelfde groep is  $\rho$ . De  $x$  onderling, de  $y$  onderling en de  $x_j$  en  $y_j$  voor  $j \neq i$  zijn ongecorreleerd; ondersteld; de verwachting der  $x_j$  en  $y_j$  zijn  $= 0$  ondersteld.

Hieruit is de regressievergelijking  $y' = a + b x$  opgemaakt, die de waarden  $y_j$ :

geeft. Tenslotte worden de gemiddelden  $a_i = \frac{x_i + y_i}{2}$   $x_1, \dots, x_n$  bepaald.

De spreidingen der  $a_i$  kunnen bij benadering bepaald worden, in de onderstelling dat de  $N$  paren  $(x_j, y_j)$  beschouwd kunnen worden als  $N$  onafhankelijke trekkingen uit een oneindig grote collectie met regressievergelijking  $y' = a + \beta x$ , en dat de verschillen van  $a$  en  $b$  met  $\alpha$  en  $\beta$  verwaardeerd kunnen worden. Dit leidt in dat  $b = \frac{\sigma_y}{\sigma_x} = \frac{\rho}{1 - \rho^2}$  door  $\beta = \rho \frac{\sigma_y}{\sigma_x} = \rho$  vervangen wordt, en dat zijn spreiding verwaardeerd wordt. (Griekse letters hebben op de oneindige collectie, latijnse op de steekproef betrekking. Laatstgenoemde zijn dus bekend, eerstgenoemde hypothetisch). Voorts dat  $a = \frac{1}{N} \sum y_j$  door de verwachting daarvan, dus 0 vervangen wordt, en dat ook hiervan de spreiding verwaardeerd wordt.

Dan is  $\sigma_{y'}^2 = \beta \sigma_x^2 = \rho^2 \frac{\sigma^2}{n}$

$\beta$ . verwachting van  $yx = \rho \sigma_y \sigma_x = \rho^2 \sigma^2 / n$

Daar

$$\sigma_{yx}^2 = \frac{\rho^2 \sigma^2 / n}{\sigma_y^2 \sigma_x^2} = \frac{\rho^2 \sigma^2 / n}{\frac{\sigma^2}{n} \rho \frac{\sigma^2}{n}} = \rho^2$$

Derhalve is wegens  $\sigma_{zz}^2 = \sigma_y^2 + \sigma_{y'}^2 + 2 \sigma_{yx}^2 =$

$$\sigma_{zz}^2 = \sigma_y^2 + \sigma_{y'}^2 + 2 \rho^2 \sigma^2 / n =$$

$$\begin{aligned}
 &= \frac{1}{n} \left[ \sigma^2 + \rho^2 \sigma^2 + 2\rho \cdot \sigma \cdot \sigma \right] \\
 &= \sigma^2 (1 + 3\rho^2) / n \\
 \sigma_2^2 &= \frac{\sigma^2 (1 + 3\rho^2)}{4n}
 \end{aligned}$$

of

$$\sigma_2 = \frac{\sigma}{\sqrt{4n}} \sqrt{1 + 3\rho^2}$$

Schrijft men dit in de vorm  $\frac{\sigma}{\sqrt{2n}} \cdot \lambda^*$  dan is de "correctiefactor"  $\lambda = \sqrt{\frac{1+3\rho^2}{2}}$  dus  $> 1$  als  $3\rho^2 > 1$ ,  $|\rho| > \frac{1}{\sqrt{3}}$  is en alleen dan. Het voordeel van het invoeren van deze grootheid zie ik echter niet in.

Schrijft men echter

$$\sigma_2 = \frac{\sigma}{\sqrt{n}} \cdot \lambda$$

dan is de correctiefactor  $\lambda = \sqrt{\frac{1+3\rho^2}{2}}$  Deze is  $\frac{1}{2}$  voor  $\rho = 0$  en  $\frac{1}{2}$  voor  $\rho = \pm 1$ .

Bij volledige correlatie vinden we dus de oorspronkelijke  $\frac{\sigma}{\sqrt{n}}$  terug. Bij volledige ongescorreerdheid  $\rho = 0$  wordt zij echter gehalveerd. Dat is als volgt te zien. Indien  $x$  en  $y$  volledig ongescorreerd waren, zou de regressielijn van  $y$  tev.  $x$  een horizontale rechte worden, dus, daar de gemiddelden 0 zijn, de  $x$ -as. D.w.z. dan waren alle  $y_i = 0$ . Dus waren de  $z_i = \frac{y_i + y'_i}{2}$  een-vendig de helften der  $y_i$ , dus ook  $\sigma_2 = \frac{1}{2}\sigma$ .

Voor  $\rho = 0,8$  wordt de factor  $\lambda = \sqrt{\frac{1+3 \cdot 0,8^2}{2}} \approx 0,905$

dus  $\sigma_2 \approx 0,905 \frac{\sigma}{\sqrt{n}} \quad (\approx 1,19 \frac{\sigma}{\sqrt{2n}})$

voor	$\rho = 0,9$	$\lambda = 0,91$
"	$\frac{1}{2}\sqrt{3} = 0,577\ldots$	0,707
	0,5	0,6
	0,3	0,555
	0,0	0,5

enzo. (alle getallen in grove benadering).

Ik herinner er nog even aan, dat altijd als  $z = \frac{y+y'}{2}$  is, (onverschillig of  $y$  al dan niet op bovenstaande wijze

wit  $y$  ontstaan is)

$$\sigma_2 = \frac{1}{2} \sqrt{\sigma_y^2 + \sigma_{y'}^2 + 2\sigma_y \sigma_{y'} \rho_{yy'}}$$

is, dus steeds

$$\sigma_2 \leq \frac{1}{2} \sqrt{\sigma_y^2 + \sigma_{y'}^2 + 2\sigma_y \sigma_{y'}} = \frac{\sigma_y + \sigma_{y'}}{2}$$

Anderzijds is ook steeds

$$\sigma_2 \geq \frac{|\sigma_y - \sigma_{y'}|}{2}$$

Als dus  $\gamma = \gamma'$  is, is  $\sigma_2$  steeds hoogstens daaraan gelijk, onverschillig of deze grootheden spreidingen van gemeten grootheden (in het bovenstaande  $\sigma$ ), dan wel de spreidingen van daaruit gevonden groepsgemiddelden (in het bovenstaande  $\sigma_2$ ) zijn.

De hier gevonden correctiefactor  $\frac{1}{2}\sqrt{1+\rho^2}$  behoeft zelf weer een correctie omdat de identificatie van  $a$  en  $b$  met  $\alpha$  resp.  $\beta$  eigenlijk niet gerechtvaardigd is, vooral omdat het aantal groepen ( $N = 34$ ) zo klein is. Exacte berekening van deze verdere correctie is niet mogelijk, approximative wellicht. Het is evenwel de vraag, of deze de moeite leent. Wanneer ik U de eindige waarde  $\sigma = 3,8$  aanhouw, evenwel met een noemer  $\sqrt{n}$  en niet  $\sqrt{2n}$  blijft U in ieder geval aan de veilige kant.

In de hoop, dat deze gegevens nog van nut kunnen zijn voor Uw rapport en ook overigens verhalderend mogen werken, verblijf ik,

hoogachtend,

(Prof.Dr.D.van Dantzig).

## ENIGE VOORIOPIGE AANTKENNINGEN BIJ HET ONDERZOEK VAN

Drs Thomasson

- Ad § 2. 1. De afronding van het gemiddelde zonder correctie is een te ruwe benadering, die systematische fouten doet ontstaan. De spreidingen worden n.l. regelmatig overschat.
- Ad § 3. 2. Aangezien  $\beta$ , een kwadraat is, moeten de mintekens voor de waarden van  $\beta$ , vervangen worden door plusstekens (Tabel I); de mintekens zouden voor de wortel uit  $\beta$ , moeten staan.
3. Voor de berekening van de standaarddeviaties van  $b_1$  en  $b_2$  zijn de Tables for Statisticians and Biometricians in dit geval niet geschikt. Het doel van Tabel I is n.l. te toetsen of de 6 beschouwende verdelingen als normaal beschouwd kunnen worden. Het procédé is dan, dat men uitgaat van de veronderstelling, dat de verdelingen normaal zijn, om vervolgens nl of niet tot een tegenspraak te komen. Men moet dus ook voor de berekening van de standaard-deviatie van  $b_1$  en  $b_2$  uitgaan van de hypothese der normaliteit. Deze gedachtegang is bij de constructie van de tabellen van Pearson niet gevolgd; men heeft daar een veel uitgebreider groep van verdelingen op het oog gehad.
4. Het is in dit verband doelmatig, gebruik te maken van het werkje "Tests of normality" van R.C. Geary and E.S. Pearson. Dit verschafft de mogelijkheid om van het werken met standaard-deviaties van  $\beta_1$  en  $\beta_2$  af te zien en direct af te lezen, hoe groot de waarschijnlijkheid is, dat als de modelcollectie normaal verdeeld is, de steekproefwaarden van  $\beta_1$  en  $\beta_2$  buiten een bepaald gebied rondom de theoretische waarden 0 resp. 3 vallen. Het resultaat is, dat het slechts in 1 op de 100 gevallen zal voorkomen, dat bij een steekproef van 1300 waarnemingen de steekproefwaarden  $b_1$  groter is dan 0.026. Kiezen we een overschrijdingskans van 5% in plaats van 1%, dan is de maximale steekproefwaarde van  $b_1$  hoogstens 0.012; het is dus dubius, of de collectie van de j<sup>2</sup> week nog geacht kan worden normaal verdeeld te zijn.
5. Op analoge wijze vinden we, dat bij een steekproef van 1300 waarnemingen de steekproefwaarde van  $b_2$  slechts in 1 op de 100 gevallen zal liggen buiten het interval (2,71 - 3,35). Uit tabel I blijkt, dat alle steekproefwaarden van  $\beta_2$  op één na duidelijk rechts van dit interval liggen. Het is duidelijk, dat de 6 beschouwde verdelingen niet normaal geacht kunnen worden.

Ad § 4. 6. Bij een voorlopig onderzoek van de analyse, die de opdrachtnemer in deze paragraaf geeft, betreffende relaties tussen spreidingen, leek het ons toe, dat de methode niet geheel correct is. Hierop zal nader worden ingegaan.

Ad § 5 en

- § 6 7. Deze paragrafen moeten nog nader onderzocht worden.  
8. De conclusie, opgesloten in de zin: "Uit het feit, dat de standaard-deviatie in de loop van de proef met een constante grootheid vermeerdert, wordt waarschijnlijk, dat tussen de gewichtsvermeerderingen in de achtereenvolgende weken een rechtlijnig verband zal voorkomen", moet zeer gewaagd geschat worden.
- 
-