


STICHTING
MATHEMATISCH CENTRUM

2e BOERHAAVESTRAAT 49
AMSTERDAM

S 73 (M 32)

Toetsing van de lineariteit van een regressielijn indien de
waarnemingsfouten onderling onafhankelijk en normaal verdeeld
zijn met gelijke spreidingen.


[1952]

Toetsing van de lineariteit van een regressielijn indien de waarnemingsfouten onderling onafhankelijk en normaal verdeeld zijn met gelijke spreidingen.¹⁾

Gegeven zij dat van twee grootheden ξ en η de grootheid ξ foutloos kan worden waargenomen, terwijl bij de waarnemingen van η onderling onafhankelijke fouten²⁾ worden gemaakt, die alle een normale³⁾ verdeling bezitten met gemiddelde 0 en onbekende, maar steeds dezelfde, spreiding σ .

Zij verder gegeven dat bij iedere waarneming x_i' ($i=1, \dots, k$) van ξ een aantal waarnemingen y_{ij}' ($j=1, \dots, n_i$) van η beschikbaar is.

Gevraagd wordt om, op grond van dit waarnemingsmateriaal, dus:

$$\begin{aligned} & (x_1', y_{11}'), (x_1', y_{12}') \dots (x_1', y_{1n_1}'), \\ & \vdots \\ & (x_h', y_{h1}'), (x_h', y_{h2}') \dots (x_h', y_{hn_1}'), \end{aligned}$$

de hypothese H_0 te toetsen dat er een lineair verband tussen η en ξ bestaat:

$$H_0: \dots \quad \eta = \beta \xi + \alpha.$$

Om H_0 te toetsen worden uit de waarnemingen schattingen b en a en voor β en α berekend door toepassing van de methode der kleinste kwadraten, die in dit geval overeenkomt met de methode der meest aannemelijke schattingen (Eng. method of maximum likelihood). Hierdoor wordt gevonden:

1) Dit memorandum is slechts bedoeld ter orientatie en streeft niet naar volledigheid of volledige exactheid.

2) Onder fouten vallen in dit geval ook toevallige afwijkingen van andere aard, bv. physiologische afwijkingen.

3) De stochastische grootheid x bezit een normale verdeling met gemiddelde μ en spreiding σ , indien voor iedere a geldt:

$$P[x \leq a] = \frac{1}{\sigma\sqrt{2\pi}} \int_{-\infty}^a e^{-\frac{1}{2} \frac{(u-\mu)^2}{\sigma^2}} du.$$

$$b = \frac{\sum_{i=1}^h n_i (x_i' - \bar{x}') y_i'}{\sum_{i=1}^h n_i (x_i' - \bar{x}')^2},$$

$$a = \bar{y}' - b \bar{x}',$$

waarin, als $N = \sum_{i=1}^h n_i$,

$$y_i' = \frac{\sum_{j=1}^{n_i} y_{ij}'}{n_i}; \quad \bar{y}' = \frac{\sum_{i=1}^h n_i y_i'}{N}; \quad \bar{x}' = \frac{\sum_{i=1}^h n_i x_i'}{N},$$

Een schatting voor σ^2 wordt gegeven door:

$$s^2 = \frac{\sum_{i=1}^h \sum_{j=1}^{n_i} (y_{ij}' - y_i')^2}{N-h} = \frac{\sum_{i=1}^h \sum_{j=1}^{n_i} y_{ij}'^2 - \sum_{i=1}^h n_i y_i'^2}{N-h}.$$

Uit de afwijkingen van de gemiddelden y_i' van de aangepaste regressielijn kan, indien de hypothese H_0 juist is, een tweede schatting voor σ^2 worden afgeleid:

$$s'^2 = \frac{\sum_{i=1}^h n_i (y_i' - b x_i' - a)^2}{h-2} = \frac{\sum_{i=1}^h n_i y_i'^2 - b^2 \sum_{i=1}^h n_i (x_i' - \bar{x}')^2 - N \bar{y}'^2}{h-2}.$$

Beschouwen we niet alleen de gevonden waarden y_{ij}' ($j=1, \dots, n_i; i=1, \dots, h$) maar de verzameling van alle mogelijke waarden die aangenomen kunnen worden, dan bezitten de genoemde schattingen op deze verzameling een waarschijnlijkheidsverdeling, die afhankelijk is van de (exact waargenomen) waarden x_i' ($i=1, \dots, h$). Dit wordt door onderstreping van de desbetreffende symbolen aangegeven.

De grootheden \underline{s}^2 en \underline{s}'^2 zijn onderling onafhankelijk verdeeld, zoals bv. door Mood [1] bewezen wordt (hoofdstuk 13)

en $\frac{(N-h)\underline{s}^2}{\sigma^2}$ en $\frac{(h-2)\underline{s}'^2}{\sigma^2}$ bezitten χ^2 -verdelingen met respectievelijk $(N-h)$ en $(h-2)$ vrijheidsgraden.

Hieruit volgt, dat de grootte

$$\underline{F} = \frac{\underline{s}'^2}{\underline{s}^2}$$

verdeeld is volgens de verdeling van de grootte \underline{F} van Snedecor met $(h-2)$ en $(N-h)$ vrijheidsgraden.

Ook wanneer er geen lineair verband tussen η en ξ bestaat zal \underline{s}^2 een goede schatting van σ^2 blijven, voor \underline{s}'^2 daarentegen en dus ook voor \underline{F} zullen de grotere waarden een grotere waarschijnlijkheid bezitten. Voor toetsingen van de hypothese H_0 gebruikt men dan ook een éézijdige kritieke zône van de vorm $\underline{F} \geq F_0$ waarbij F_0 , behorende bij een bepaalde onbetrouwbaarheidsdrempel α en bepaalde aantallen vrijheidsgraden, opgezocht kan worden in tabellen vermeld in onderstaande literatuurlijst

Litteratuur.

- [1] A.M. Mood. Introduction to the theory of statistics, Mc. Graw-Hill, New York-Toronto-London, 1950, hoofdstuk 13 (regressie-theorie), hoofdstuk 14, p.322 (lineariteitstoets), pp.426-427 (tabel).
- [2] H. Cramer. Mathematical methods of statistics, Princeton Un. Press., Princeton 1946.
- [3] C.W. Emmens. Principles of Biological assay, Chapman and Hall Ltd, London, 1948, pp. 30-33 (tabellen).