

ÜBER DAS ASYMPTOTISCHE VERHALTEN DER RAND- UND ZENTRALGLIEDER EINER VARIATIONSREIHE I

von

HANS-JOACHIM ROBBERG¹

Wir betrachten n unabhängige Zufallsgrößen x_1, \dots, x_n mit der Verteilungsfunktion $\mathbf{P}\{x_i < x\} = F(x)$. Bei einem Experiment an diesen x_i mögen die Werte X_i ($i = 1, \dots, n$) eingetreten sein. Dann ist die Ranggröße $\xi_k = R_k(X_1, \dots, X_n)$ als der k -te Wert unter den X_i definiert, wenn diese der Größe nach angeordnet sind. Die so definierten Ranggrößen, die infolge der Beziehung $\xi_1 \leq \xi_2 \leq \dots \leq \xi_n$ voneinander abhängig sind, bilden eine sog. Variationsreihe. Unter den genannten Voraussetzungen hat die Theorie des Grenzverhaltens für $n \rightarrow \infty$ der Ranggrößen in vieler Hinsicht abschließende Resultate erzielt. Kaum behandelt wurden jedoch bisher die Beziehungen zwischen Rand- und Zentralgliedern einer Variationsreihe, die wir hier untersuchen wollen.

Wir beweisen einen Satz über die Unabhängigkeit im Limes von Ranggrößen. Was die Randglieder einer Variationsreihe betrifft, d. h. Ranggrößen ξ_h und ξ_k mit $h = \text{const}$ und $n - k = \text{const}$, so wurde ihre Unabhängigkeit im Limes (unter gewissen Voraussetzungen) von E. J. GUMBEL [2] festgestellt. Einen exakten Beweis dieser Tatsache und eine Verallgemeinerung lieferte T. HOMMA [3]. In einem sehr starken Sinne bewies J. GEFFROY [1] die Unabhängigkeit im Limes von Randgliedern. Den Fall zweier Zentralglieder $\left(\frac{h}{n} \rightarrow \lambda_1, \frac{k}{n} \rightarrow \lambda_2, 0 < \lambda_1 < \lambda_2 < 1, \text{ d.h. } \lim \frac{h}{k} > 0\right)$ behandelte N. W. SMIRNOFF [6]. Er zeigte, daß Unabhängigkeit im Limes nicht auftritt, wenn der Vektor (ξ_h, ξ_k) im Limes einer zweidimensionalen Normalverteilung unterworfen ist. Wir zeigen nun, daß Rand- und Zentralglieder stets im Limes unabhängig voneinander sind. In Bezug auf Formulierung und Beweis von Satz 1 verdanke ich Herrn Professor A. RÉNYI wertvolle Hinweise.

Satz 1. *Die Rangnummern h und k mögen derart von n abhängen, daß $\lim_{n \rightarrow \infty} \frac{h}{k} = 0$. Dann sind die Ranggrößen ξ_h und ξ_k im Limes unabhängig, d. h. für*

$$\sigma_n = \sup_{\substack{-\infty < u < \infty \\ -\infty < v < \infty}} |\mathbf{P}(\xi_h < u, \xi_k < v) - \mathbf{P}(\xi_h < u) \mathbf{P}(\xi_k < v)|$$

gilt $\lim_{n \rightarrow \infty} \sigma_n = 0$. In derselben Weise sind auch ξ_{n+1-h} und ξ_{n+1-k} im Limes voneinander unabhängig.

¹ Berlin.

Beweis. Die letzte Behauptung läßt sich auf die erste zurückführen, indem man die Zufallsgrößen $\bar{x}_i = -x_i$ heranzieht, die auf die Variationsreihe $\bar{\xi}_i = -\xi_{n+1-i}$ ($i = 1, \dots, n$) führen.

Wir definieren neue unabhängige Zufallsgrößen durch die Transformation

$$y_i = -\log(1 - F(x_i)) \quad (i = 1, \dots, n).$$

Sie geben Anlaß zu der Variationsreihe

$$\eta_i = -\log(1 - F(\xi_i)) \quad (i = 1, \dots, n).$$

Mit \mathfrak{M} bezeichnen wir die Menge der Zahlen y , für die mindestens eine Zahl \hat{y} existiert, so daß $y = -\log(1 - F(\hat{y}))$. Für $y \in \mathfrak{M}$ gilt

$$\begin{aligned} \mathbf{P}\{y_i < y\} &= G(y) = \mathbf{P}\{-\log(1 - F(x_i)) < -\log(1 - F(\hat{y}))\} = \\ &= \mathbf{P}\{x_i < \hat{y}\} = F(\hat{y}) = 1 - e^{-y}. \end{aligned}$$

Alle Zahlen $y \notin \mathfrak{M}$ liegen in Konstanzintervallen von $G(y)$. Wenn $F(x)$ stetig ist, haben somit die Zufallsgrößen y_i eine exponentielle Verteilungsfunktion. Im anderen Falle bildet der Wertevorrat von $G(y)$ nur eine echte Teilmenge des Intervalls $[0, 1]$. Nun ist

$$\begin{aligned} \sigma_n &= \sup_{u, v} |\mathbf{P}\{\eta_h < -\log(1 - F(u)), \eta_k < -\log(1 - F(v))\} - \\ &\quad - \mathbf{P}\{\eta_h < -\log(1 - F(u))\} \mathbf{P}\{\eta_k < -\log(1 - F(v))\}| = \\ &= \sup_{x, y \in \mathfrak{M}} |\mathbf{P}\{\eta_h < x, \eta_k < y\} - \mathbf{P}\{\eta_h < x\} \mathbf{P}\{\eta_k < y\}|. \end{aligned}$$

Die Funktion, deren Supremum hier gebildet wird, läßt sich aber in der Form $Q_{hk}(G(x); G(y))$ darstellen. Die Verteilungsfunktion von η_k unter der Bedingung $\eta_h = u$ ist nämlich gleich der Verteilungsfunktion der Ranggröße mit der Nummer $k - h$ in einer Stichprobe vom Umfang $n - h$ mit der Grundverteilung

$$\frac{G(y) - G(u)}{1 - G(u)} \quad (y \geq u)$$

(vgl. [5], § 2). Daher gilt für $x \leq y$

$$\begin{aligned} \mathbf{P}\{\eta_h < x, \eta_k < y\} &= \int_0^x \mathbf{P}\{\eta_k < y | \eta_h = u\} d\mathbf{P}\{\eta_h < u\} = \\ &= \binom{n}{h} \binom{n-h}{k-h} \int_0^{G(x)} \left\{ \int_0^{\frac{G(y)-w}{1-w}} (1-s)^{n-k} ds^{k-h} \right\} d \int_0^w (1-t)^{n-h} dt^h \end{aligned}$$

und für $x > y$

$$\mathbf{P}\{\eta_h < x, \eta_k < y\} = \mathbf{P}\{\eta_k < y\} = \binom{n}{k} \int_0^{G(y)} (1-t)^{n-k} dt^k.$$

Führen wir unabhängige Zufallsgrößen z_i mit $\mathbf{P}(z_i < z) = 1 - e^{-z}$ ($z \geq 0$, $i = 1, \dots, n$) ein, die die Variationsreihe ζ_1, \dots, ζ_n liefern, setzen wir ferner

$$\mathbf{P}\{\zeta_h < x, \zeta_k < y\} - \mathbf{P}\{\zeta_h < x\} \mathbf{P}\{\zeta_k < y\} = R_{hk}(x, y),$$

so gilt die Abschätzung

$$\sigma_n \leq \sup_{x,y} |R(1 - e^{-x}, 1 - e^{-y})| = \sup_{x,y} |R_{hk}(x, y)|.$$

Damit ist unser allgemeines Problem auf ein viel einfacheres zurückgeführt, das wir mit Hilfe des folgenden Lemmas behandeln werden.

Lemma 1. Wenn $h \rightarrow \infty, \frac{h}{k} \rightarrow 0, n - k \rightarrow \infty$, so ist gilt gleichmäßig bezüglich x und y

$$R_{hk}(x, y) = \mathbf{P}\{\zeta_h < x, \zeta_k < y\} - \mathbf{P}\{\zeta_h < x\} \mathbf{P}\{\zeta_k < y\} \rightarrow 0.$$

Beweis. Da die Differenz $\zeta_k - \zeta_h$ unabhängig von ζ_h ist, (s. z. B. [4]), gilt

$$\begin{aligned} R_{hk}(x, y) &= \int_0^x [\mathbf{P}\{\zeta_k < y | \zeta_h = u\} - \mathbf{P}\{\zeta_k < y\}] d\mathbf{P}\{\zeta_h < u\} = \\ (1) \quad &= \int_0^x [\mathbf{P}\{\zeta_k - \zeta_h < y - u\} - \mathbf{P}\{\zeta_k < y\}] d\mathbf{P}\{\zeta_h < u\}. \end{aligned}$$

Man erkennt leicht, daß $R_{hk}(x, y) \geq 0$ für alle x und y .

A. RÉNYI [4] hat eine Methode eingeführt, die es gestattet, Grenzwertsätze für Ranggrößen in einer sehr eleganten Weise zu gewinnen. Wir sind jetzt in der Lage, sie anzuwenden. Es gilt die Darstellung

$$(2) \quad \zeta_k = \frac{\delta_1}{n} + \frac{\delta_2}{n-1} + \dots + \frac{\delta_k}{n+1-k},$$

wo die Zufallsgrößen $\delta_1, \dots, \delta_k$ unabhängig sind und die Verteilungsfunktion $\mathbf{P}\{\delta_j < y\} = 1 - e^{-y}$ ($y \geq 0$) haben, so daß für ihre mathematischen Erwartungen und Dispersionen

$$\mathbf{M} \delta_j = \mathbf{D}^2 \delta_j = 1 \quad (j = 1, \dots, k)$$

gilt. Daraus folgt

$$\begin{aligned} M_k &= \mathbf{M} \zeta_k = \sum_{i=n+1-k}^n \frac{1}{i} = M_{kh} + M_h \\ (3) \quad S_k^2 &= \mathbf{D}^2 \zeta_k = \sum_{i=n+1-k}^n \frac{1}{i^2} = S_{kh}^2 + S_h^2, \end{aligned}$$

und wegen $\mathbf{M} |\delta_j - 1|^3 = \int_0^\infty |x - 1|^3 e^{-x} dx < \int_0^\infty e^{-x} dx + \int_0^\infty x^3 e^{-x} dx \leq 5$ gilt ferner

$$T_k^3 = \sum_{i=1}^k \mathbf{M} \left| \frac{\delta_i - 1}{n + 1 - i} \right|^3 \leq 5 \sum_{i=n+1-k}^n \frac{1}{i^3} < 5 \int_{n-k}^n \frac{dt}{t^3} < \frac{5k}{n(n-k)^2}.$$

Durch derartige Integralabschätzungen (nach unten und oben) der Summen M_h und S_k^2 findet man weiter ($0 < \vartheta < 1$)

$$(4) \quad M_h = (1 + o(1)) \log \frac{n}{n-h} = \frac{h}{n} (1 + o(1))$$

$$S_k^2 = \frac{k}{(n-k)n} \left(1 + \vartheta \frac{n}{(n-k)k} \right) = \frac{k}{(n-k)n} (1 + o(1))$$

und somit

$$\frac{T_k^3}{S_k^3} \leq 5 \sqrt{\frac{n}{(n-k)k}} \rightarrow 0.$$

Daher läßt sich auf die Summe (2) der Satz von Ljapunoff anwenden, d. h. es gilt

$$(5) \quad \lim_{n \rightarrow \infty} \mathbf{P} \left\{ \frac{\zeta_k - M_k}{S_k} < x \right\} = \Phi(x) = \frac{1}{\sqrt{2\pi}} \int_{-\infty}^x e^{-\frac{t^2}{2}} dt.$$

Wegen $M_{kh} = \mathbf{M}(\zeta_k - \zeta_h) = \sum_{i=n+1-k}^{n-h} \frac{1}{i}$, $S_{kh}^2 = \mathbf{D}^2(\zeta_k - \zeta_h) = \sum_{i=n+1-k}^{n-h} \frac{1}{i^2}$ braucht man in den obigen Rechnungen nur n und k durch $n-h$, bzw. $k-h$ zu ersetzen, um mit Hilfe von $\frac{h}{k} \rightarrow 0$ die Beziehungen

$$(6) \quad S_{kh}^2 = S_k^2 (1 + o(1))$$

und

$$(7) \quad \lim_{n \rightarrow \infty} \mathbf{P} \left\{ \frac{\zeta_k - \zeta_h - M_{kh}}{S_{kh}} < x \right\} = \Phi(x)$$

zu gewinnen. Da die Konvergenz in (5) und (7) gleichmäßig bezüglich x ist, ergibt sich aus (1)

$$(8) \quad R_{hk}(x, y) = \int_0^x \left[\Phi \left(\frac{y-u-M_{kh}}{S_{kh}} \right) - \Phi \left(\frac{y-M_k}{S_k} \right) \right] d\mathbf{P}(\zeta_h < u) + r_n(x, y) = \\ = J_n(x, y) + r_n(x, y)$$

und das Restglied r_n konvergiert gleichmäßig in x und y gegen 0.

Bei beliebigem $y \geq 0$ bestimmen wir die Zahl $\hat{x}(y)$ durch die Gleichung

$$\frac{y - \hat{x} - M_{kh}}{S_{kh}} = \frac{y - M_k}{S_k}, \quad \text{oder} \quad \hat{x} = \frac{y - M_k}{S_k} (S_k - S_{kh}) + M_h.$$

Nach (3) gilt $S_k - S_{kh} > 0$. Falls $\frac{y - M_k}{S_k} \rightarrow -\infty$ und dabei $\hat{x} < 0$, folgt

wegen $\frac{y - M_{kh}}{S_{kh}} < \frac{y - M_k}{S_k}$ aus (8) die Behauptung des Lemmas. Wenn

$\frac{y - M_k}{S_k} > -C^2$, ist für genügend große n $\hat{x} > 0$, denn mit (4) und (6) folgt $\frac{S_k - S_{kh}}{M_h} = \frac{S_h^2}{M_h(S_k + S_{kh})} < k^{-\frac{1}{2}}$. Für $\hat{x} > 0$ aber ist bei festem y $\sup_x J_n(x, y) = J_n(\hat{x}, y)$. Wenn $\frac{y - M_k}{S_k} \rightarrow \infty$, folgt nun aus (8) unmittelbar die Behauptung.

Es bleibt noch übrig, den Fall $\frac{y - M_k}{S_k} < C^2$, $\hat{x} > 0$ zu betrachten. Bei beliebigem $\eta > 0$ gilt die Abschätzung

$$(9) \quad J_n(\hat{x}, y) = \int_0^{\hat{x} - \eta S_{kh}} \dots + \int_{\hat{x} - \eta S_{kh}}^{\hat{x}} \dots \leq \mathbf{P}\{\zeta_h < \hat{x} - \eta S_{kh}\} + \left[\Phi\left(\frac{y - M_k}{S_k} + \eta\right) - \Phi\left(\frac{y - M_k}{S_k}\right) \right].$$

Das zweite Glied kann mit η gleichmäßig beliebig klein gemacht werden; das erste aber ist kleiner als $\mathbf{P}\left\{\frac{\zeta_h - M_h}{S_h} < C \frac{S_k - S_{kh}}{S_h} - \eta \frac{S_{kh}}{S_h}\right\}$ und verschwindet nach dem Satz von Ljapunoff für $n \rightarrow \infty$. Die Gleichung (5) gilt nämlich auch mit h an Stelle von k , und ebenso können wir in (4) k durch h ersetzen. Daher folgt mit Hilfe von (6) für genügend große n

$$\frac{S_k - S_{kh}}{S_h} = \frac{S_k^2 - S_{kh}^2}{S_h(S_k + S_{kh})} = \frac{S_h}{2S_k} (1 + o(1)) < \sqrt{\frac{h}{k}} \rightarrow 0$$

und

$$\frac{S_{kh}}{S_h} = \frac{S_k}{S_h} (1 + o(1)) \rightarrow \infty.$$

Damit ist das Lemma bewiesen.

Jetzt müssen wir uns noch von den Voraussetzungen $h \rightarrow \infty, n - k \rightarrow \infty$ befreien. Wir beginnen mit der letzteren, betrachten also die Funktion $R_{hl}(x, y)$ für $h \rightarrow \infty, \frac{h}{l} \rightarrow 0, n - l \rightarrow \infty$. Dann existiert eine Zahlenfolge $k(n)$, so daß $\frac{h}{k} \rightarrow 0, n - k \rightarrow \infty, k \leq l$. Da die Ranggrößen ζ_1, \dots, ζ_n eine Markoffsche Kette bilden, sind ζ_h und ζ_l unter der Bedingung $\zeta_k = u$ unabhängig, und es gilt

$$R_{hl}(x, y) = \int_0^y \mathbf{P}\{\zeta_l < x \mid \zeta_k = u\} [\mathbf{P}\{\zeta_h < x \mid \zeta_k = u\} - \mathbf{P}\{\zeta_h < x\}] d\mathbf{P}\{\zeta_k < u\}.$$

Natürlich brauchen wir nur Werte von y zu betrachten, für die der Integrand im Intervall $(0, y)$ positiv ist. Für solche Werte aber gilt

$$R_{hl}(x, y) \leq \int_0^y [\mathbf{P}\{\zeta_h < x \mid \zeta_k = u\} - \mathbf{P}\{\zeta_h < x\}] d\mathbf{P}\{\zeta_k < u\} = R_{hk}(x, y).$$

Auf Grund des Lemmas 1 ist damit der betrachtete Fall erledigt. Mit Hilfe dieses Resultats läßt sich aber in der gleichen Weise auch der Fall $h \leftrightarrow \infty$ behandeln. Damit ist Satz 1 bewiesen.

(Eingegangen: 28. August 1960; in umgearbeiteter Form: 1. April 1962.)

LITERATURVERZEICHNIS

- [1] GEFFROY, J.: Publ. Inst. Stat. Paris 1958 und 1959.
- [2] GUMBEL, E. J.: Ann. Math. Stat. 1946.
- [3] HOMMA, T.: Reports of statistical application research 1, Tokio, 1951.
- [4] RÉNYI, A.: Acta Math. Acad. Sci. Hung. 1953.
- [5] ROBBERG, H. J.: Math. Nachrichten 1960.
- [6] SMIRNOFF, N. W.: Bull. de l'Université d'État à Moscou, Ser. Inter., Section B, Math. et Méc. 1, 1937.

ОБ АСИМПТОТИЧЕСКОМ ПОВЕДЕНИИ ЦЕНТРАЛЬНОГО И КРАЙНЕГО ЧЛЕНОВ ПОРЯДКОВЫХ СТАТИСТИК

Н. J. ROBBERG

Резюме

Используя метод А. РЭНИИ автор доказывает, что упорядоченные статистики ξ_h и ξ_k являются асимптотически независимыми, если $n \rightarrow \infty$, $\frac{h}{k} \rightarrow 0$.