

Е. Б. ДЫНКИН

О ДОСТАТОЧНЫХ И НЕОБХОДИМЫХ СТАТИСТИКАХ ДЛЯ СЕМЕЙСТВА РАСПРЕДЕЛЕНИЯ ВЕРОЯТНОСТЕЙ

(Представлено академиком А. Н. Колмогоровым 14 IX 1950)

В предлагаемой работе исследуется общая задача вычисления достаточных статистик (см. ⁽¹⁾, стр. 530—531, а также ⁽²⁾) для заданного семейства одномерных распределений вероятностей. Мы рассматриваем статистики, принимающие векторные значения; очевидно, при этом отпадает необходимость изучать отдельно достаточные системы статистик. Определение 2 вводит новое понятие необходимой статистики. Если знание любой достаточной статистики дает достаточный материал для того, чтобы оценивать неизвестный параметр, достаточный в том смысле, что знание полного результата наблюдений не добавляет к этому материалу ничего существенного, то знание всякой необходимой статистики необходимо для того, чтобы не происходила существенная потеря информации. Для каждого семейства распределений при фиксированном объеме выборки существует единственная с точностью до эквивалентности необходимая и достаточная статистика. Теорема 1 дает путь для ее вычисления. Вместе с тем теорема 1 вводит важное понятие ранга семейства распределений. Для семейств бесконечного ранга понятие достаточной статистики является бесплодным. Все семейства конечного ранга выделяются теоремой 2 (частным случаем последней является теорема Дармуа ⁽³⁾). В математической статистике важную роль играют семейства распределений, получающиеся из некоторых распределений линейными преобразованиями прямой линии. Специальному исследованию таких семейств распределений посвящены теоремы 3 и 4*.

Мы рассматриваем семейство \mathfrak{S} одномерных распределений $P_\theta(A)$ (параметр θ пробегает некоторое вспомогательное множество S). При этом мы предполагаем, что в некотором интервале Δ (конечном или бесконечном) каждое распределение $P_\theta(A)$ задается плотностью $p(x, \theta)$, являющейся положительной кусочно гладкой функцией ** (условие регулярности). Пусть производится серия из n независимых испытаний, причем результаты каждого испытания подчинены одному и тому же закону распределения из класса \mathfrak{S} . Возможные результаты образуют n -мерное пространство R^n .

Определение 1. Достаточной статистикой для семейства распределений \mathfrak{S} в интервале по выборке объема n называется всякая функция $\chi(x_1, \dots, x_n)$, принимающая значения из некоторого векторного пространства R^m , определенная для всех $x_1 \in \Delta, \dots, x_n \in \Delta$ и удовлетворяющая в этой области соотношению

$$p(x_1, \theta) p(x_2, \theta) \dots p(x_n, \theta) = \bar{p}(\chi(x_1, x_2, \dots, x_n), \theta) q(x_1, x_2, \dots, x_n).$$

* Эти теоремы дают, в частности, ответ на поставленный А. Н. Колмогоровым вопрос о том, какой вид могут иметь достаточные статистики для указанных семейств распределений.

** Функцию $p(x)$ мы называем кусочно гладкой в Δ , если существует область $G \subset \Delta$ такая, что $\bar{G} = \Delta$ и $dp(x)/dx$ существует и непрерывна в G .

Положим сокращенно $(x_1, x_2, \dots, x_n) = x$. Пусть $\chi_1(x)$ и $\chi_2(x)$ — две функции, определенные в некоторой области G пространства R^n . Условимся говорить, что χ_2 подчинена χ_1 , если из $\chi_1(x') = \chi_1(x'')$ вытекает $\chi_2(x') = \chi_2(x'')$. Будем называть функции χ_1 и χ_2 эквивалентными, если каждая из них подчинена другой. Статистика $\varepsilon(x) = x$ достаточна для любой системы распределений. Мы будем говорить, что статистика $\chi(x)$ тривиальна в области G , если она эквивалентна $\varepsilon(x)$ в некоторой области $\tilde{G} \subset G$.

Определение 2. Необходимой статистикой для семейства распределений \mathfrak{S} в интервале Δ по выборке объема n называется всякая функция, определенная для $x_1 \in \Delta, x_2 \in \Delta, \dots, x_n \in \Delta$ и подчиненная в этой области любой достаточной статистике.

Теорема 1. Пусть θ_0 — произвольный элемент S . Положим $g_x(\theta) = \ln p(x, \theta) - \ln p(x, \theta_0)$ и обозначим через L минимальное линейное пространство функций, определенных на Δ , содержащее константы и содержащее при любом $\theta \in S$ функцию $g_x(\theta)$. Пусть размерность L равна $r+1$ (не исключено, что $r = \infty$). Тогда:

А. Для всякого конечного $n \leq r$ произвольная достаточная статистика для семейства \mathfrak{S} в интервале Δ по выборке объема n тривиальна.

Б. Если функции $1, \varphi_1(x), \varphi_2(x), \dots, \varphi_r(x)$ образуют базис в L , то при любом $n \geq r$ система функций

$$\chi_i(x_1, x_2, \dots, x_n) = \varphi_i(x_1) + \varphi_i(x_2) + \dots + \varphi_i(x_n) \\ (i = 1, 2, \dots, r; \quad x_1, \dots, x_n \in \Delta)$$

функционально независима и образует необходимую и достаточную статистику для семейства \mathfrak{S} в интервале Δ по выборке объема n .

Число r , определяемое теоремой 1, мы назовем рангом системы распределений \mathfrak{S} в интервале Δ .

Теорема 2. Для того чтобы система распределений \mathfrak{S} имела конечный ранг в интервале Δ , необходимо и достаточно, чтобы плотность $p(x, \theta)$ представилась в виде

$$p(x, \theta) = \exp \left(\sum_{i=1}^r \varphi_i(x) c_i(\theta) + c_0(\theta) + \varphi_0(x) \right) \quad (x \in \Delta, \theta \in S),$$

где $\varphi_1(x), \dots, \varphi_r(x)$ кусочно гладки в интервале Δ . Если при этом $1, \varphi_1(x), \dots, \varphi_r(x)$ и $1, c_1(\theta), \dots, c_r(\theta)$ линейно независимые системы функций, то ранг \mathfrak{S} равен r и для $n \geq r$ система функций

$$\chi_i(x_1, \dots, x_n) = \varphi_i(x_1) + \varphi_i(x_2) + \dots + \varphi_i(x_n) \\ (i = 1, 2, \dots, r; \quad x_1, \dots, x_n \in \Delta)$$

функционально независима и образует необходимую и достаточную статистику для \mathfrak{S} по выборке объема n .

Теорема 3. Пусть каждому $\theta \in S$ сопоставлена функция распределения $F(x, \theta)$. Пусть семейство \mathfrak{S} этих распределений удовлетворяет в интервале Δ условию регулярности. Тогда:

А. Если для некоторого $\delta > 0$ семейство \mathfrak{S}_1 распределений $F(x - \alpha, \theta)$ ($|\alpha| < \delta, \theta \in S$) имеет конечный ранг в Δ , то плотность $p(x, \theta)$ представляется в виде

$$p(x, \theta) = \exp \left(\sum_{i=1}^s c_i(\theta) x^{n_i} e^{\mu_i x} \right) \quad (x \in \Delta, \theta \in S), \quad (1)$$

где μ_i — комплексные, n_i — целые постоянные, $c_i(\theta)$ — функции, принимающие комплексные значения.

Б. Если Δ не содержит нуля и для некоторого $p > 1$ семейство \mathfrak{S}_2 распределений $F(x/\sigma, \theta)$ ($\theta \in S, 1/p < \sigma < p$) имеет конечный ранг

в Δ , то плотность $p(x, \theta)$ представляется в виде

$$p(x, \theta) = \exp \left(\sum_{i=1}^s c_i(\theta) (\ln |x|)^{n_i} |x|^{u_i} \right) \quad (x \in \Delta, \theta \in S) \quad (2)$$

($\mu_i, n_i, c_i(\theta)$ как в формуле (1)).

В. Если для некоторых $\delta > 0$ и $p > 1$ семейство \mathfrak{S}_3 распределений $F\left(\frac{x-\alpha}{\sigma}, \theta\right)$ ($\theta \in S, |\alpha| < \delta, \frac{1}{p} < \sigma < p$) имеет конечный ранг в Δ , то

$$p(x, \theta) = \exp Q(x, \theta) \quad (x \in \Delta, \theta \in S), \quad (3)$$

где $Q(x, \theta)$ — многочлен относительно x с комплексными коэффициентами, зависящими от θ .

Необходимая и достаточная статистика для семейства \mathfrak{S}_1 может быть образована из функций вида $x_1^k e^{\lambda x_1} + x_2^k e^{\lambda x_2} + \dots + x_n^k e^{\lambda x_n}$; для семейства \mathfrak{S}_2 — из функций вида $|x_1|^\lambda (\ln |x_1|)^k + |x_2|^\lambda (\ln |x_2|)^k + \dots + |x_n|^\lambda (\ln |x_n|)^k$ и для семейства \mathfrak{S}_3 — из функций вида $x_1^k + x_2^k + \dots + x_n^k$ (k — целые, λ — комплексные постоянные)*.

Для многих важных распределений задающая их функция плотности вероятностей равна нулю вне некоторого интервала. Если рассматривать в качестве интервала Δ всю прямую, то условие регулярности здесь не выполняется и теорема 3 непосредственно не применима. Вместо нее может быть использована следующая теорема.

Теорема 4. Пусть функция $p(x, \theta)$ при каждом θ из S представляет плотность вероятностей некоторого одномерного распределения. Пусть при всех $\theta \in S$ $p(x, \theta)$ положительна и кусочно гладка относительно x в некотором интервале Δ и равна нулю вне Δ . Обозначим через \mathfrak{S}_1 семейство распределений $p(x - \alpha, \theta)$ ($\theta \in S, -\infty < \alpha < +\infty$), через \mathfrak{S}_2 — семейство распределений $\frac{1}{\sigma} p\left(\frac{x}{\sigma}, \theta\right)$ ($\theta \in S, 0 < \sigma < \infty$) и через \mathfrak{S}_3 — семейство распределений $\frac{1}{\sigma} p\left(\frac{x-\alpha}{\sigma}, \theta\right)$, ($\theta \in S, -\infty < \alpha < +\infty, 0 < \sigma < +\infty$). Для того чтобы семейства $\mathfrak{S}_1, \mathfrak{S}_2, \mathfrak{S}_3$ имели конечный ранг на всей прямой, необходимо и достаточно, чтобы для $\theta \in S, x \in \Delta$ плотность $p(x, \theta)$ представлялась, соответственно, в виде (1), (2) или (3) (в случае \mathfrak{S}_2 дополнительно предполагается, что интервал Δ не содержит нуля).

Для семейств \mathfrak{S}_1 и \mathfrak{S}_3 необходимая и достаточная статистика дается системой функций, указанных в теореме 3, если $\Delta = (-\infty, +\infty)$. Эта система функций должна быть пополнена функцией $\min(x_1, x_2, \dots, x_n)$ в случае $\Delta = (a, +\infty)$ (a конечно) и функцией $\max(x_1, x_2, \dots, x_n)$ в случае $\Delta = (-\infty, b)$ (b конечно). Наконец, в случае $\Delta = (a, b)$, где a и b конечны, к системе функций теоремы 3 должны быть присоединены обе функции $\min(x_1, x_2, \dots, x_n)$ и $\max(x_1, x_2, \dots, x_n)$. Аналогично, для семейства \mathfrak{S}_2 необходимая и достаточная статистика совпадает с указанной в теореме 3, если $\Delta = (0, +\infty)$ или $\Delta = (-\infty, 0)$; получается из указанной в теореме 3 статистики присоединением $\min(x_1, x_2, \dots, x_n)$, если $\Delta = (a, +\infty)$ ($a > 0$) или $\Delta = (-\infty, b)$ ($b < 0$); присоединением $\max(x_1, x_2, \dots, x_n)$, если $\Delta = (0, a)$ ($0 < a < +\infty$) или $\Delta = (b, 0)$ ($-\infty < b < 0$), и присоединением $\max(x_1, \dots, x_n)$ и $\min(x_1, \dots, x_n)$, если $\Delta = (a, b)$, где a и b конечны и отличны от нуля.

Примеры.

1. Гауссовская плотность $p(x) = \frac{1}{\sqrt{2\pi}} e^{-x^2/2}$ имеет вид (3). В со-

* Нетрудно указать тот набор пар (k, λ) , которому отвечает система функций, дающих необходимую и достаточную статистику. Из-за недостатка мест мы опускаем формулировку соответствующего правила.

ответствии с теоремой 3 пара функций $\left(\sum_{i=1}^n x_i, \sum_{i=1}^n x_i^2\right)$ является необходимой и достаточной статистикой для семейства распределений $\frac{1}{\sigma} p\left(\frac{x-\alpha}{\sigma}\right)$.

2. Исследуем семейство распределений, задаваемое на положительной полуоси плотностями

$$p(x, \beta, \gamma, \mu) = Cx^\beta e^{-\gamma x^\mu}. \quad (4)$$

Если μ известно, то необходимая и достаточная статистика задается парой функций $\left(\sum_{i=1}^n x_i^\mu, \sum_{i=1}^n \ln x_i\right)$ при неизвестных β и γ^* , функцией

$\sum_{i=1}^n \ln x_i$ при неизвестном β и известном γ и функцией $\sum_{i=1}^n x_i^\mu$ при известном γ и известном β . Если μ неизвестно, то ранг семейства (4) в любом интервале Δ бесконечен и, значит, нетривиальные достаточные статистики отсутствуют (последнее было впервые доказано Пинскером).

3. Для семейства $p(x - \alpha, \beta, \gamma, \mu)$, где $p(x, \beta, \gamma, \mu)$ определено формулой (4), при известном μ необходимая и достаточная статистика получается, согласно теореме 4, присоединением к функциям, указанным в примере 2, функции $\min(x_1, x_2, \dots, x_n)$. При неизвестном μ ранг рассматриваемого семейства бесконечен.

4. Плотность

$$p(x, \theta, \alpha_1, \sigma_1, \alpha_2, \sigma_2) = \frac{\theta}{\sqrt{2\pi}\sigma_1} e^{-(x-\alpha_1)^2/2\sigma_1^2} + \frac{(1-\theta)}{\sqrt{2\pi}\sigma_2} e^{-(x-\alpha_2)^2/2\sigma_2^2}$$

($0 < \theta < 1$) получается смешивание двух гауссовских плотностей. Если хотя бы один из параметров $\theta, \alpha_1, \sigma_1, \alpha_2, \sigma_2$ неизвестен, то соответствующее семейство распределений имеет бесконечный ранг.

5. Для семейства распределений Лапласа $p(x, \alpha, \sigma) = \frac{1}{2\sigma} e^{-|x-\alpha|/\sigma}$ при известном α необходимая и достаточная статистика равна $\sum_{i=1}^n |x_i - \alpha|$. При неизвестном α семейство имеет ранг ∞ .

6. Плотность $p(x) = e^{-(x+e^{-x})}$ встречается при исследовании предельного поведения максимума m независимых случайных величин при $m \rightarrow \infty$. Для семейства распределений $p(x - \alpha)$ необходимая и достаточная статистика равна $\sum_{i=1}^n e^{-x_i}$ (ср. теорему 3).

7. Рассмотрим произвольный интервал (a, b) и равномерное распределение в этом интервале. Семейство всех таких распределений получается из любого одного из них линейными преобразованиями. Необходимая и достаточная статистика дается парой функций $\min(x_1, x_2, \dots, x_n)$ и $\max(x_1, x_2, \dots, x_n)$ (этот пример был впервые рассмотрен А. Н. Колмогоровым (4)).

Поступило
28 VI 1950

ЦИТИРОВАННАЯ ЛИТЕРАТУРА

- ¹ Н. Срамер, Math. Methods of Statistics, 1946; русск. пер. Г. Крамер, Математические методы статистики, М., 1948. ² А. Н. Колмогоров, Изв. АН СССР, сер. матем., 14, № 4 (1950). ³ G. Darrois, C. R., 200, 1265 (1935). ⁴ А. Н. Колмогоров, Изв. АН СССР, сер. матем. (1942).

* Выражение « μ известно, β и γ неизвестны» означает, что рассматривается семейство распределений $p(x, \beta, \gamma, \mu)$, где μ фиксировано, а β и γ изменяются в некоторых интервалах.