

А.Х. ШЕНЬ

## ПОНЯТИЕ $(\alpha, \beta)$ -СТОХАСТИЧНОСТИ ПО КОЛМОГОРОВУ И ЕГО СВОЙСТВА

(Представлено академиком А.Н. Колмогоровым 11 XI 1982)

Мы исследуем свойства введенного А.Н. Колмогоровым понятия стохастического конечного объекта. Говоря неформально, стохастические объекты — это "элементы общего положения" простых множеств. Приведем точные определения.

В качестве конечных объектов мы будем рассматривать натуральные числа. Говоря об энтропии (= сложности) числа  $x$ , будем иметь в виду его простую колмогоровскую энтропию, введенную в [1]. Энтропия числа  $x$  будет обозначаться  $K(x)$ . Нам потребуется говорить также об энтропии конечных множеств натуральных чисел. Для этого мы фиксируем какую-либо естественную нумерацию конечных множеств (например, описанную в [2]) и под энтропией множества  $A$  будем понимать энтропию его номера. Энтропия множества  $A$  будет обозначаться  $K(A)$ .

**Определение (А.Н. Колмогоров).** Пусть  $\alpha, \beta$  — натуральные числа. Число  $x$  будем называть  $(\alpha, \beta)$ -стохастическим, если существует такое конечное множество  $A \subset \mathbb{N}$ , что

$$x \in A, \quad K(A) \leq \alpha, \quad K(x) \geq \log_2 |A| - \beta;$$

здесь через  $|A|$  обозначено число элементов множества  $A$ .

Первое неравенство (если  $\alpha$  невелико) означает, что множество  $A$  достаточно просто. Второе (если  $\beta$  невелико) означает, что элемент  $x$  является "элементом общего положения" в множестве  $A$ . Действительно, если бы  $x$  обладал какими-нибудь особенностями, которые свойственны лишь очень малой части  $Q$  множества  $A$ , то их можно было бы использовать для простого описания  $x$ , указав его порядковый номер в списке всех элементов  $Q$ , что потребовало бы  $\log_2 |Q|$  бит, т.е. много меньше  $\log_2 |A|$ .

Установим связь понятия  $(\alpha, \beta)$ -стохастичности с основаниями математической статистики. Пусть мы проводим некоторый вероятностный эксперимент, результатом которого а priori может быть любое натуральное число. Пусть результатом этого эксперимента оказалось число  $x$ . Зная  $x$ , мы хотим восстановить распределение вероятностей  $P$  на множестве  $\mathbb{N}$  всех натуральных чисел. Разумно требовать, чтобы, во-первых,  $P$  имело простое описание, а во-вторых,  $x$  было бы "типичным" исходом опыта с распределением вероятностей  $P$ . (На практике специфика задачи часто заранее подсказывает возможный вид  $P$  и остается выбрать какие-то его параметры; мы, однако, считаем, что единственное имеющееся у нас сведение о  $P$  — это полученное значение  $x$ .)

Уточним сказанное. В качестве распределений вероятностей будем рассматривать всюду определенные функции  $P: \mathbb{N} \rightarrow \mathbb{Q}$ , все значения которых неотрицательны,  $P(x) = 0$  для всех  $x$ , кроме конечного числа, и  $\sum_x P(x) \leq 1$ . (Мы допускаем возможность  $\sum_x P(x) < 1$ , считая, что наш эксперимент может и не дать результата.) Чтобы говорить об энтропии таких функций, фиксируем какую-либо естественную нумерацию их натуральными числами и, говоря об энтропии функции, будем иметь в виду (простую колмогоровскую) энтропию ее номера. Энтропию распределения  $P$  будем обозначать  $K(P)$ . Теперь требование простоты распределения  $P$  превращается в требование малости его энтропии. Требование

”типичности”  $x$  для распределения  $P$  мы уточним так:

$K(x)$  не должно быть много меньше  $-\log_2 P(x)$ .

Если, например,  $P$  приписывает вероятность  $1/2^n$  всем числам от 0 до  $2^n - 1$ , то ”типичными” будут те  $x \in \{0, \dots, 2^n - 1\}$ , для которых энтропия  $K(x)$  близка к  $n$ .

Отметим, что  $K(x)$  не может сильно превосходить  $-\log_2 P(x)$ , если распределение  $P$  достаточно просто. Именно, при любом  $x$  справедливо неравенство

$$K(x) \leq -\log_2 P(x) + K(P) + O(\log_2(-\log_2 P(x) + K(P))).$$

В самом деле, пусть  $1/2^{k+1} \leq P(x) \leq 1/2^k$ . Рассмотрим множество всех  $t$ , для которых  $P(t) \geq 1/2^{k+1}$ . В нем не более  $2^{k+1}$  элементов, и  $x$  — один из них. Чтобы задать  $x$ , достаточно указать это множество и порядковый номер элемента  $x$  в нем. Для указания множества достаточно указать  $P$  и число  $k$ ; указание порядкового номера требует не более  $k + 1$  бит. Отсюда и вытекает написанное неравенство. Требование ”типичности”  $x$  гарантирует, что это неравенство будет близко к равенству (если энтропия  $P$  невелика).

Следующее определение выделяет те  $x$ , для которых возможно найти распределение  $P$  с описанными свойствами.

**О п р е д е л е н и е.** Пусть  $\alpha, \beta$  — натуральные числа. Число назовем  $(\alpha, \beta)$ -к в а з и с т о х а с т и ч е с к и м, если существует такое распределение  $P$  (из описанного класса), что

$$K(P) \leq \alpha, \quad K(x) \geq -\log_2 P(x) - \beta.$$

Понятия стохастичности и квазистохастичности оказываются весьма близкими. Именно, имеет место

**Т е о р е м а 1.** *Существуют такие константы  $C_1$  и  $C_2$ , что для любого числа  $x$ :*

а) *если  $x$  является  $(\alpha, \beta)$ -стохастическим, то  $x$  является  $(\alpha + C_1, \beta)$ -квазистохастическим;*

б) *если  $x$  является  $(\alpha, \beta)$ -квазистохастическим и  $x \in \{0, \dots, 2^n - 1\}$ , то  $x$  является  $(\alpha + C_1 \log_2 n, \beta + C_2)$ -стохастическим.*

Эта теорема показывает, что стохастичность и квазистохастичность ”совпадают с точностью до  $\log_2 n$ ”.

**Д о к а з а т е л ь с т в о.** Утверждение а) доказывается легко. Пусть  $x \in A$ , (энтропия  $A$ )  $\leq \alpha$ ,  $K(x) \geq \log_2 |A| - \beta$ . Рассмотрим распределение  $P$ , приписывающее всем элементам множества  $A$  одинаковые вероятности, равные  $1/|A|$ , и всем остальным числам — нулевые вероятности. Очевидно, энтропия  $P$  превосходит энтропию  $A$  не более, чем на константу, а  $\log_2 |A| = -\log_2 P(x)$ . Отсюда и получаем требуемое.

Чуть более сложно доказывается утверждение б). Пусть число  $x$  является  $(\alpha, \beta)$ -квазистохастическим. Тогда существует такое распределение  $P$ , энтропия которого не превосходит  $\alpha$ , а  $K(x) \geq -\log_2 P(x) - \beta$ . Пусть  $k$  — такое число, что  $2^{-(k+1)} \leq P(x) < 2^{-k}$ . Тогда  $K(x) \geq k - \beta$ . Из этого неравенства и из неравенства  $K(x) \leq n + O(1)$  вытекает, что  $k \leq n + \beta + O(1)$  (эта оценка потребуется нам в дальнейшем). Рассмотрим теперь множество  $A$ , состоящее из всех  $y \in \mathbb{N}$ , для которых  $P(y) \geq 2^{-(k+1)}$ . Чтобы задать  $A$ , достаточно указать  $P$  и указать  $k$ , поэтому энтропия  $A$  не превосходит  $\alpha + C \log_2(n + \beta)$ . Множество  $A$  содержит не более  $2^{k+1}$  элементов, поэтому  $K(x) \geq \log_2 |A| - (\beta + 1)$ . Таким образом,  $x$  является  $(\alpha + C \log_2(n + \beta), \beta + 1)$ -стохастическим. Если  $\beta \leq n$ , то утверждение п. б) доказано. Если же  $\beta > n$ , то любое число от 0 до  $2^n - 1$  является  $(C \log_2 n, \beta)$ -стохастическим (достаточно в качестве  $A$  взять множество всех чисел от 0 до  $2^n - 1$ ). Теорема 1 доказана.

Обратимся теперь к вопросу о том, при каких  $\alpha$  и  $\beta$  среди чисел от 0 до  $2^n - 1$  существуют не  $(\alpha, \beta)$ -стохастические. Ответ на этот вопрос дает

**Теорема 2. а)** Существует такое  $C$ , что при любом  $n$  и любых  $\alpha$  и  $\beta$ , для которых  $\alpha \geq \log_2 n + C$ ,  $\alpha + \beta \geq n + 4\log_2 n + C$ , все числа от 0 до  $2^n - 1$  являются  $(\alpha, \beta)$ -стохастическими.

**б)** Существует такое  $C$ , что при любом  $n$  и любых  $\alpha$  и  $\beta$ , для которых  $2\alpha + \beta < n - 6\log_2 n - C$ , не все числа от 0 до  $2^n - 1$  являются  $(\alpha, \beta)$ -стохастическими.

**Доказательство. а)** Пусть сначала  $\beta \leq n$ . Разобьем числа от 0 до  $2^n - 1$  на  $2^{n-\beta}$  множеств по  $2^\beta$  элементов в каждом (например, отнеся к  $i$ -му множеству числа от  $2^\beta i$  до  $2^\beta(i+1)$ ). Чтобы задать любое из этих множеств, нужно задать  $n$ ,  $\beta$  и число от 0 до  $2^{n-\beta}$ , указывающее, каким по счету оно является в нашем разбиении. Поэтому энтропия любого из множеств разбиения не превосходит  $2\log_2 n + 2\log_2 \beta + (n - \beta) + C$ , т.е.  $\leq n - \beta + 4\log_2 n + C$  (здесь  $C$  — константа, не зависящая от  $n, \alpha, \beta$ ). Если  $\alpha + \beta \geq n + 4\log_2 n + C$ , то энтропия любого из множеств разбиения не превосходит  $\alpha$ , поэтому все числа от 0 до  $2^n - 1$  будут  $(\alpha, \beta)$ -стохастическими. (Второе неравенство из определения  $(\alpha, \beta)$ -стохастичности выполнено, так как в правой части его стоит  $\log_2 2^\beta - \beta = 0$ .) Если же  $\beta \geq n$ , то, взяв в качестве  $A$  множество  $\{0, 1, \dots, 2^n - 1\}$ , мы убедимся, что его энтропия не превосходит  $\log_2 n + C$  (и, следовательно, не превосходит  $\alpha$ ) и все его элементы являются  $(\alpha, \beta)$ -стохастическими.

**б)** Пусть  $\alpha$  фиксировано. Рассмотрим список  $A_1, A_2, \dots, A_s$  всех конечных множеств, энтропия которых не превосходит  $\alpha$ . Очевидно,  $s \leq 2^{\alpha+1}$ . Мы хотим оценить энтропию семейства  $A_1, A_2, \dots, A_s$ . Чтобы задать это семейство, достаточно указать (помимо  $\alpha$ ) то из описаний множеств  $A_1, A_2, \dots, A_s$ , на обработку которого выбранному способу описания требуется больше всего шагов. Поэтому энтропия указанного семейства не превосходит  $\alpha + 2\log_2 \alpha + C_1$ , где  $C_1$  — некоторая константа, не зависящая от  $\alpha$ . Рассмотрим те из множеств  $A_1, A_2, \dots, A_s$ , которые имеют менее  $2^{n-\alpha-1}$  элементов. Рассмотрим наименьшее число  $x$ , не содержащееся в их объединении. Это число меньше  $2^n$ , так как  $s$  не превосходит  $2^{\alpha+1}$ , а каждое из множеств  $A_1, A_2, \dots, A_s$  имеет менее  $2^{n-\alpha-1}$  элементов.

Чтобы задать число  $x$ , нужно указать  $A_1, A_2, \dots, A_s, \alpha$  и  $n$ , поэтому его энтропия не превосходит

$$\alpha + 2\log_2 \alpha + 2\log_2 \alpha + 2\log_2 n + C'$$

и тем более  $\alpha + 6\log_2 n + C'$  (здесь  $C'$  — константа, не зависящая от  $n$  и  $\alpha$ .) Докажем, что если

$$\beta < n - 6\log_2 n - (C' + 1) - 2\alpha,$$

то построенное нами  $x$  не является  $(\alpha, \beta)$ -стохастическим. Из этого будет следовать утверждение теоремы при  $C = C' + 1$ . В самом деле, если  $x$  является  $(\alpha, \beta)$ -стохастическим, то  $x \in A_i$  и  $K(x) \geq \log_2 |A_i| - \beta$  при некотором  $i$ . Множество  $A_i$  должно содержать не менее  $2^{n-\alpha-1}$  чисел (иначе  $x$  не принадлежало бы ему), поэтому  $K(x) \geq n - \alpha - 1 - \beta$ . Но  $K(x) \leq \alpha + 6\log_2 n + C'$ , откуда  $\alpha + 6\log_2 n + C' \geq n - \alpha - 1 - \beta$  и  $\beta \geq n - 6\log_2 n - 2\alpha - 1 - C'$ . Теорема 2 доказана.

Утверждение теоремы 2 указывает границу для  $\alpha/n$  и  $\beta/n$ , при переходе через которую исчезают последние нестохастические объекты. Эта граница (для случая  $\alpha = \beta$ ) находится где-то между  $1/2$  и  $1/3$ .

Следующая теорема отвечает на вопрос о доле  $(\alpha, \beta)$ -стохастических чисел среди всех чисел от 0 до  $2^n - 1$ .

**Теорема 3.** Существует такое  $C$ , что для всех  $n$  и для всех  $\alpha$  и  $\beta$ , для которых  $\alpha \geq C \log_2 n$ , количество чисел от 0 до  $2^n - 1$ , не являющихся

$(\alpha, \beta)$ -стохастическими, заключено между

$$[2^{n-2\alpha-\beta-C\log_2 n}] \text{ и } 2^{n-\alpha-\beta+C\log_2 n};$$

$[a]$  есть целая часть числа  $a$ .

**Доказательство.** Оценим сначала количество нестохастических чисел сверху. Как и при доказательстве теоремы 2, разобьем множество чисел от 0 до  $2^n - 1$  на  $2^p$  частей по  $2^{n-p}$  чисел в каждой. Энтропия каждой части не превосходит  $p + O(\log_2 n)$ , поэтому, выбрав  $p = \alpha - C\log_2 n$  при подходящем  $C$ , можно добиться, чтобы энтропия любой части не превосходила  $\alpha$ . При этом все числа, энтропия которых больше  $n - p - \beta$ , будут  $(\alpha, \beta)$ -стохастическими. Поэтому количество нестохастических чисел не превосходит  $2^{n-p-\beta} = 2^{n-\alpha-\beta+C\log_2 n}$ . Верхняя оценка получена.

Чтобы получить нижнюю оценку, рассмотрим все множества, энтропия которых не превосходит  $\alpha$ , а число элементов не превосходит  $2^{n-\alpha-2}$ . Энтропия списка всех таких множеств не превосходит  $\alpha + O(\log_2 n)$ . Объединение всех множеств этого списка содержит не более половины всех чисел от 0 до  $2^n - 1$ . Через  $a_i$  обозначим  $i$ -е (в порядке возрастания) число, не входящее в это объединение (при  $i < 2^{n-1}$ ). В силу сказанного  $a_i < 2^n$  при любом  $i < 2^{n-1}$ . Энтропия  $a_i$  не превосходит  $\alpha + O(\log_2 n) + O(\log_2 \alpha) + \log_2 i$ ;  $(\alpha, \beta)$ -стохастическими среди  $a_i$  могут быть лишь те, для которых энтропия превосходит  $n - 2 - \alpha - \beta$ , т.е.  $\alpha + O(\log_2 n) + \log_2 i \geq n - \alpha - 2 - \beta$  и  $\log_2 i \geq n - 2\alpha - \beta - O(\log_2 n)$ . Поэтому имеется по крайней мере  $[2^{n-2\alpha-\beta-O(\log_2 n)}]$  нестохастических чисел. Теорема 3 доказана.

Она показывает, что (с точностью до  $\log_2 n$ ) доля  $(\alpha, \beta)$ -стохастических чисел среди всех чисел от 0 до  $2^n - 1$  заключена между  $1 - 1/2^{\alpha+\beta}$  и  $1 - 1/2^{2\alpha+\beta}$ .

С точки зрения рассмотренной статистической интерпретации представляет интерес вопрос о том, какова вероятность появления нестохастических чисел в вероятностном эксперименте. Более точно, пусть  $P$  — некоторое распределение вероятностей на множестве чисел от 0 до  $2^n - 1$ . Что можно сказать о  $P(Q)$ , где  $Q$  — множество всех нестохастических чисел (при данных  $\alpha$  и  $\beta$ )? Естественно желать, чтобы  $P(Q)$  было мало. Если не требовать ничего от  $P$ , то добиться этого нельзя:  $P$ , например, может придавать вероятность 1 некоторому нестохастическому числу. Однако если  $P$  имеет малую энтропию, то можно получить желаемую оценку.

**Теорема 4.** Существует такое  $C$ , что для любого распределения вероятностей  $P$ , энтропия которого не превосходит  $\alpha$ , величина  $P(Q)$ , где  $Q$  — множество всех чисел от 0 до  $2^n - 1$ , не являющихся  $(\alpha + C\log_2 n, \beta)$ -стохастическими, не превосходит  $2^{-\beta+C\log_2 n}$ .

**Доказательство.** Применяя теорему 1, можно доказывать утверждение с заменой  $(\alpha + C\log_2 n, \beta)$ -стохастичности на  $(\alpha, \beta)$ -квазистохастичность. А это делается так. Для всех  $x$ , не являющихся  $(\alpha, \beta)$ -квазистохастическими,  $K(x) < -\log_2 P(x) - \beta$  или  $P(x) < 2^{-K(x) - \beta}$ . Отсюда

$$\sum_{x - \text{не } (\alpha, \beta)\text{-квазистохастическое}} P(x) < 2^{-\beta} \sum_{x \in \{0, \dots, 2^n - 1\}} 2^{-K(x)};$$

правая часть не превосходит  $n + O(1)$ , так как количество тех  $x$ , для которых  $K(x) = a$ , не превосходит  $2^a$ . Отсюда мы и получаем утверждение теоремы 4.

Институт проблем передачи информации  
Академии наук СССР, Москва

Поступило  
26 XII 1982

#### ЛИТЕРАТУРА

1. Колмогоров А.Н. — Пробл. передачи информации, 1965, т. 1, вып. 1, с. 3–11. 2. Роджерс Х. Теория рекурсивных функций и эффективная вычислимость. М.: Мир, 1972. 624 с.