

# Измерение объективной степени случайности конечного набора точек

В.И. Арнольд

июнь 2009

## 1. Определение двух параметров стохастичности

Вопрос о том, насколько “объективно случайна” наблюдаемая выборка значений — один из труднейших в прикладной математике. Описанные ниже числовые характеристики стохастичности,  $\beta$  и  $\lambda$ , доставляют некоторые объективные меры степени случайности данного конечного набора вещественных чисел (или точек окружности). Объективны они в том смысле, что выводы не зависят от происхождения исследуемого набора (который может оказаться “случайным” и доставляясь простым алгоритмом, вроде “датчика случайных чисел” теоретико-числового происхождения).

Хотя оба эти параметра,  $\beta$  и  $\lambda$ , кажутся совершенно независимыми характеристиками выборки, описанные ниже эксперименты показывают, что между их усредненными вариантами  $\hat{\beta}$  и  $\hat{\lambda}$  появляется неожиданная эмпирическая функциональная зависимость (16).

Мы будем рассматривать системы (“выборки”)  $k$  точек конечной (дискретной) окружности  $\mathbb{Z}_n = \mathbb{Z}/(n\mathbb{Z})$  длины  $n$ .

Определение 1. (см.[1]). *Параметр стохастичности  $B$*  принимает на данной выборке значение

$$B = a_1^2 + a_2^2 + \dots + a_k^2, \quad (1)$$

где  $a_j \geq 0$  — длины тех  $k$  дуг, на которые изучаемые  $k$  точек делят окружность,  $\mathbb{Z}_n$  длины  $n$ .

$$a_1 + a_2 + \dots + a_k = n. \quad (2)$$

Наименьшее значение  $B_0$  параметра стохастичности  $B$  достигается в центре симплекса (2). Оно равно

$$B_0 = k(n/k)^2 = n^2/k.$$

Среднее значение  $B_*$  параметра  $B$  примерно вдвое больше минимального: в [1] доказано, что

$$B_* = B_0(2k/(k+1)). \quad (3)$$

Определение 2. (см.[1]). *Безразмерным параметром стохастичности* (системы  $k$  точек дискретной окружности  $\mathbb{Z}_n$ ) называется значение  $\beta$  параметра стохастичности  $B$  (определенного формулой (1)) нормализованное его делением на наименьшее возможное значение  $B_0$  параметра  $B$  :

$$\beta = B/B_0 \quad (4)$$

Нормализующее деление на  $B_0$  позволяет сравнивать между собой значения параметров стохастичности для окружностей разных длин  $n$  (в то время, как значение исходного параметра  $B$  имеет размерность площади, будучи пропорциональным квадрату длины рассматриваемой окружности).

Замечание. По определению,  $\beta \geq 1$ , а в среднем  $\beta \approx \beta_*$ , (где  $\beta_* = 2k/(k+1) \approx 2$  при больших  $k$  по формуле (3)). Меньшие среднего значения (грубо говоря,  $\beta < 2$ ) соответствуют взаимному *отталкиванию* между соседними точками (которое в предельном случае  $\beta = 1$  представляет их “военным” строем со всюду равными  $n/k$  расстояниями между соседними точками “кристаллической решетки” точек).

Бóльшие среднего значения (грубо говоря,  $\beta > 2$ ) соответствуют взаимному *притяжению* соседних точек (приводящему к их сгущению в “кластеры”, вплоть до предельного случая максимального значения

$$\beta_1 = k, \quad (5)$$

реализуемого вершинами симплекса (2), т.е. скоплением всех  $k$  точек в одном месте:  $a_1 = a_2 = \dots = a_k = 0$ ).

Оба эти случая — отталкивания и притяжения — означают, что изученные точки *зависимы* — степень их взаимной зависимости измеряется разностью  $\beta - \beta_*$ .

Если изучаемые  $k$  точек независимо друг от друга брошены на окружность  $\mathbb{Z}_n$ , то вычисленное по ним значение безразмерного параметра стохастичности  $\beta$  не слишком далеко от среднего значения  $\beta_*$ , т.е. (при больших  $k$ ) должно наблюдаться  $\beta \approx 2$ .

Совершенно другой параметр стохастичности,  $\lambda$ , был предложен А.Н. Колмогоровым [2] в итальянской статье 1933 года. В применении к нашей ситуации ( $k$  точек на дискретной окружности  $\mathbb{Z}_n$  длины  $n$ ) значение этого параметра вычисляется следующим образом.

Обозначим наши  $k$  точек значениями целочисленных остатков от деления их координат на  $n$ :

$$0 \leq x_1 \leq x_2 \leq \dots \leq x_k \leq n. \quad (6)$$

Вместо выборки остатков (6) А.Н. Колмогоров рассматривает *считающую функцию*  $C_k$  со значениями

$$C_k(\Lambda) = (\text{число значений } x_j \leq \Lambda). \quad (7)$$

Эта считающая функция вещественного аргумента  $\Lambda$  (где  $0 \leq \Lambda \leq n$ ) кусочно-постоянная между изучаемыми точками: если  $x_1 < x_2 < \dots < x_k$ , то

$$C_k(\Lambda) = 0, \text{ при } \Lambda < x_1,$$

$$C_k(\Lambda) = 1, \text{ при } x_1 \leq \Lambda < x_2,$$

$$C_k(\Lambda) = m, \text{ при } x_m \leq \Lambda < x_{m+1},$$

$$C_k(\Lambda) = k, \text{ при } \Lambda \geq x_k \text{ (например, } C_k(n) = k).$$

Предполагая, что выборка (6) есть (записанный в возрастающем порядке) набор независимых значений одной и той же случайной величины, Колмогоров рассматривает “теоретически считающую функцию”

$$C_0(\Lambda) = (\text{математическое ожидание числа } x_m < \Lambda) = k(\text{вероятность события } x < \Lambda). \quad (8)$$

Это — тоже неубывающая функция, тоже растущая от  $C_0(0) = 0$  до  $C_0(n) = k$ . В среднем функции  $C_k$  и  $C_0$  растут одинаково (прирастая на  $k$  при увеличении  $\Lambda$  на  $n$ ).

Здесь Колмогоров предполагает, что функция  $C_0$  непрерывна. В этом случае он доказывает поразительную (релятивистскую) теорему об универсальном распределении для отклонения  $C_k$  от  $C_0$  при больших  $k$ .

А именно, отклонение  $S_k$  определяется у него формулой

$$S_k[x] = \sup_{\Lambda} |C_k(\Lambda) - C_0(\Lambda)|. \quad (9)$$

Супремум стоит здесь вместо максимума потому, что считающая функция  $C_k$  имеет разрывы в точках  $x_m$ .

Релятивистской эта теория является в том смысле, что расстояние (9) не зависит от выбора координаты на оси  $\Lambda$ : выбор  $\Lambda^2$  привёл бы к тому же значению расстояния  $S$ .

Отклонение  $C_k - C_0$  можно истолковать как сумму  $k$  слагаемых разностей с математическим ожиданием нуль у каждого из них (поскольку в среднем  $C_k$  и  $C_0$  растут одинаково). Поэтому естественно ожидать, что эта сумма — величина порядка  $\sqrt{k}$  (как для суммы независимых слагаемых).

Поэтому, чтобы сравнивать выборки с разными значениями влияния  $k$ , Колмогоров делит значение  $S$  на  $\sqrt{k}$ , определяя свой (нормализованный) параметр стохастичности  $\lambda_k$  формулой

$$\lambda_k[x] = S_k[x]/\sqrt{k}. \quad (10)$$

*Теорема Колмогорова* состоит в том, что при  $k \rightarrow \infty$  случайные величины  $\lambda_k$  сходятся (в смысле равномерной сходимости их функций распределения) к универсальной случайной величине Колмогорова,  $\lambda$ .

*Универсальность* состоит здесь в том, что функция распределения предельной величины  $\lambda$  не зависит от того, с какой (непрерывной) функции распределения  $C_0$  начиналась конструкция.

А именно, Колмогоров вычисляет свою универсальную предельную функцию распределения  $\Phi$  ( $\Phi(\Lambda) =$  вероятность события  $\lambda \leq \Lambda$ ) как  $\theta$ -функцию следующего вида:

$$\Phi(\Lambda) = \sum_{m=-\infty}^{\infty} ((-1)^m e^{-2m^2 \Lambda^2}), \quad \Lambda \geq 0. \quad (11)$$

Распределение Колмогорова ведет себя так:

$\Phi(0) = 0$  со всеми производными, а при  $\Lambda > 0$  эта функция монотонно растёт до  $\Phi(\infty) = 1$ .

При этом, например, Колмогоров вычислил значения

$$\Phi(0,4) \approx 0,003, \quad \Phi(1,8) \approx 0,997.$$

Можно вычислить среднее по распределению Колмогорова  $\Phi$  значение его параметра  $\Lambda$  оно составляет  $\Lambda_* = \sqrt{\frac{\pi}{2}} \ln 2 \approx 0,87$

Как слишком большие, так и слишком малые значения параметра стохастичности Колмогорова данной выборки  $x$  указывают на весьма малую вероятность случайности этой выборки (как событие  $\lambda \leq 0,4$ , так и событие  $\lambda \geq 1,8$ , имеют вероятности меньше трети процента).

Пример. Рассмотрим следующие две последовательности, каждая из которых состоит из 15 двузначных чисел (остатков от деления на 100).

$$03, 09, 27, 81, 43, 29, 87, 61, 83, 49, 47, 41, 23, 69, 07 \quad (12)$$

$$37, 74, 11, 48, 85, 22, 59, 96, 33, 70, 07, 44, 81, 18, 55 \quad (13)$$

На вид обе последовательности одинаково случайны, но вычисление значений параметра Колмогорова показывают, что первая последовательность (геометрическая прогрессия) примерно в 300 раз случайнее второй (арифметической прогрессии).

А именно, (предполагая теоретическое распределение равномерным) формулы (9), (10) дают соответственно:

$$\lambda_{15}^{(12)} \approx 0,70, \quad \lambda_{15}^{(13)} \approx 0,33.$$

Из формулы (11) в этих точках получаются значения:

$$\Phi(0,70) \approx 0,30, \quad \Phi(0,33) \approx 0,001.$$

Вероятность столь малого значения  $\lambda \approx 0,33$ , какое доставляет последовательность (13), примерно в 300 раз меньше вероятности (умеренного) значения  $\lambda$  порядка 0,77 (близкого к  $\Lambda_*$ ).

Применять в нашем случае (точек на конечной окружности  $\mathbb{Z}_n$ ) теорему Колмогорова *формально* нельзя, так как его предположения не выполняются.

Во-первых, дискретное распределение (точек из  $\mathbb{Z}_n$ ) не может иметь непрерывной функции распределения.

Во-вторых, топология окружности (гомологии) отлична от топологии прямой  $R$ , на которой Колмогоров рассматривает свои считающие функции.

Поэтому я предлагаю обобщить теорему Колмогорова на случай случайных величин со значениями на окружности следующим образом.

Считающие функции — это, в сущности, *первообразные* изучаемых распределений точек. На прямой Колмогоров выбирает в качестве первообразной определенный интеграл

$$I(\Lambda) = \int_{-\infty}^{\Lambda} f(\lambda) d\lambda.$$

На окружности начала отсчета “ $-\infty$ ” нет, так что первообразных много. Первообразная определена с точностью до выбора в неопределенном интеграле “постоянной интегрирования”.

Чтобы избежать этой топологической трудности, я предлагаю модифицировать формулу расстояния (9) теории Колмогорова следующим образом.

Во-первых, выберем обе сравниваемые первообразные (на накрывающей прямой) произвольно.

Во-вторых, вычтем из разности (9) постоянную так, чтобы *минимизировать* расстояние между первообразными: постоянные интегрирования надо выбрать так, чтобы минимизировать модуль разности.

Иными словами, формула (9) заменяется на формулу

$$S_k = \inf_c \sup_{\Lambda \in R} |C_k(\Lambda) - C_0(\Lambda) - c| \quad (14)$$

Определенное нижней гранью (14) расстояние уже не зависит от сделанного выбора первообразных.

Я предполагаю, что соответствующие варианты теоремы Колмогорова (об универсальности) должны выполняться и для случайных величин со значениями на окружности (с расстоянием (14) вместо (9)), и для целочисленных случайных величин ( $x \in \mathbb{Z}$  или  $x \in \mathbb{Z}_n$ ) со значениями на целочисленной прямой или на целочисленной окружности.

При этом, если шаг дискретной решетки достаточно мал, то соответствующее гипотетическое универсальное предельное распределение будет предположительно близким к распределению Колмогорова.

Я не доказываю этих гипотез и не использую их ниже, но без них настоящая работа не имела бы быть придумана: она основана на физическом предположении, что дискретные распределения на решетках с достаточно малым шагом не должны давать других явлений, чем истинно непрерывные распределения.

Главное в теореме Колмогорова — релятивистское соображение, которое ее и доказывает: все распределения с непрерывными функциями распределения переводятся друг в друга сохраняющим меру гомоморфизмом, а потому все их инвариантные относительно этих преобразований свойства одинаковы.

## 2. Совместное распределение обоих параметров стохастичности

В качестве примера ниже рассматриваются случаи системы  $k = 6$  точек на окружности  $\mathbb{Z}_{17}$  длины  $n = 17$ .

Число таких конфигураций (рассматриваемых с точностью до 17 вращений окружности  $\mathbb{Z}_{17}$ ) равно  $728 (= 3^6 - 1)$ <sup>1</sup>. Для каждой из этих 728 конфигураций я сосчитал в [3] значения параметров стохастичности  $\beta$  и  $\lambda$ . Получилось 728 “хаотически распределенных” точек на плоскости с координатами  $\beta$  и  $\lambda$ .

Чтобы избавиться от влияния локальных хаотических флуктуаций, я разбил все эти 728 точек на десяток групп близких точек и заменил каждую такую группу ее центром тяжести,  $(\hat{\beta}, \hat{\lambda})$ ,

Эти центры тяжести оказались уже менее хаотическими, чем исходные 728 точек — десяток центров тяжести удивительно точно попадает на вполне регулярную кривую (а именно, на неожиданную параболу) на плоскости с координатами  $\beta$  и  $\lambda$ .

Разбиение на группы производилось так: в группу номер  $m$  включались те конфигурации, для которых значения размерного параметра стохастичности  $B$  лежат в интервале

$$10m \leq B < 10(m + 1). \quad (15)$$

Средние значения величин  $(\hat{B}, \hat{\lambda}, \hat{\beta}$  и т.д.) определяются как средние арифметические значений соответствующих величин  $(B, \lambda, \beta$  и т.д.) для всех членов группы номер  $m$ .

В [3] доказывается

Теорема. *Средние значения по группам (15) имеют для 728 конфигураций  $k = 6$  точек*

<sup>1</sup>Это видно, например, из того, что  $C_{17}^6/17 = \frac{16 \cdot 15 \cdot 14 \cdot 13 \cdot 12}{720} = 27^2 - 1$ .

Мы воспользовались тем, что никакое нетривиальное вращение окружности  $\mathbb{Z}_{17}$  не переводит в себя никакое разбиение этой окружности на 6 дуг, поскольку число 17 — простое. Никакой связи шестерок точек из  $\mathbb{Z}_{17}$  с полями Галуа из  $3^6$  элементов я не знаю.

конечной окружности  $Z_{17}$  следующие приближенные значения:

$m$	4	5	6	7	8	9	10	11	12	14
$\hat{B}$	49	56,7	64,5	73,5	84	96	101	112	129	149
$\hat{\beta}$	1,02	1,17	1,33	1,52	1,74	1,99	2,09	2,32	2,67	3,08
$1000\hat{\lambda}$	264	387	471	530	591	651	681	725	791	865

Доказательство состоит в переборе 728 случаев, каждый из которых исследуется геометрически примерно за четверть часа. Получившиеся десять усредненных точек на плоскости с координатами  $\hat{\lambda}$  и  $\hat{\beta}$  удивительно близко лежат к параболе

$$\hat{\beta} = p + q\hat{\lambda} + r\hat{\lambda}^2, \quad (16)$$

(где  $p \approx 1,11$ ,  $q \approx -1,57$ ,  $r \approx 4,44$ .)

Никакой причины для этой эмпирически найденной неожиданной функциональной зависимости я не знаю, но вот ее график.





Рис. 1. Гистограмма распределения 728 значений параметра  $\lambda$

Вычисления, доказывающие приведенную теорему, доставляют также негауссовскую функцию распределения  $\Psi$  значений параметра  $\lambda$  (для распределения  $r = 6$  точек на окружности  $Z_{17}$ ):



В качестве среднего значения параметра стохастичности  $\lambda$  системы 6 случайных точек на окружности длины 17 это распределение доставляет значение  $\lambda_* \approx 0,532$ .

Замечание. Эти данные показывают следующее отличие предполагаемого универсального распределения  $\Psi$  параметра  $\lambda$  (для систем точек на окружности) от универсального распределения  $\Phi$  теоремы Колмогорова: распределение в случае окружности,  $\Psi$ , систематически сдвинуто влево, в сторону меньших значений параметра стохастичности  $\lambda$  по сравнению с  $\Phi$ . Например, среднее значение параметра стохастичности  $\lambda$  для распределения Колмогорова  $\lambda_{*\Phi} = \sqrt{\pi/2} \ln 2 \approx 0,87$  примерно на 60% выше, чем среднее значение  $\lambda_{*\Psi} \approx 0,53$ , получающееся для случайных 6 точек на дискретной окружности длины 17.

### Цитированная литература.

- [1] В.И. Арнольд. Группы Эйлера и арифметика геометрических прогрессий. — МЦНМО, Москва, 2003, 44 стр.
- [2] A.N. Kolmogorov. Sulla determinazione empirica di una legge di distribuzione. — G. Ist. Ital. Attuari, 4 (1933), 83–91.
- [3] V.I. Arnold. Comparison of two stochasticity parameters. — FAOM, Springer, 2009, 20 pp.

### Резюме.

Для случайного распределения  $k$  точек на целочисленной окружности  $\mathbb{Z}_n$  длины  $n$  два “параметра стохастичности”  $\beta$  и  $\lambda$  были определены (независимо друг от друга) А.Н.Колмогоровым в 1933 году и В.И.Арнольдом в 2003 году.

В статье показано, что эти параметры, кажущиеся независимыми характеристиками поля случайных точек, становятся функционально зависимыми, когда их значения усреднены по малым флуктуациям точек поля.

### Ключевые слова.

Комбинаторика — случайные распределения — притяжение — отталкивание — арифметические датчики случайных чисел — распределение Колмогорова — релятивистский метод теории вероятностей — конечная дискретная окружность.