

Занятие 4.

Вероятность в теории чисел. Метод второго момента.

Следующий результат, принадлежащий Эрдешу, использует довольно неожиданную вероятностную конструкцию.

Назовем множество $A \subset \mathbb{Z}$ *свободным от сумм*, если не найдется трех (не обязательно различных) элементов $a, b, c \in A$ таких, что $a + b = c$.

Теорема. Каждое множество B из n ненулевых целых чисел содержит свободное от сумм подмножество A , содержащее $|A| > n/3$ чисел.

Доказательство. Выберем простое число $p = 3k + 2$ так, что все элементы множества B меньше, чем k . Докажем, что можно найти $A \subset B$ требуемой мощности свободным от сумм по модулю p (то есть $a + b - c$ не кратно p для всех a, b, c в A). Заметим, что множество $C := \{k + 1, k + 2, \dots, 2k + 1\}$ свободно от сумм по модулю p . Выберем случайно остаток $a \in \{1, 2, \dots, p - 1\}$ по модулю p согласно равномерному распределению и рассмотрим случайную величину

$$X = |a \cdot C \cap B| = \sum_{c \in C} |\{ac\} \cap B|$$

(здесь мы отождествляем B с множеством остатков по модулю p). Заметим, что математическое ожидание случайной величины $|\{ac\} \cap B|$ равно $|B|/(p - 1)$, поскольку числа ac пробегают при меняющемся a по разу все ненулевые остатки по модулю p . Таким образом, $E(X) = |C| \cdot |B|/(p - 1) > |B|/3$. Значит, найдется такое a , что $|a \cdot C \cap B| > |B|/3$. В качестве A можно взять $a \cdot C \cap B$.

Упражнение. Если a_i ($i = 1, 2, \dots, s$) — целые числа, то найдется такая константа $c > 0$, что в любом конечном множестве $B \subset \mathbb{Z}$ найдется подмножество $A \subset B$ такое, что $|A| \geq c|B|$ и $\sum a_i x_i \neq 0$ для любых $x_i \in A$.

Перейдем от комбинаторной теории чисел к “настоящей”.

Рассмотрим следующий вопрос: как распределено количество $\nu(k)$ различных простых делителей наугад выбранного от 1 до n натурального числа k ?

Оказывается, что это количество почти для всех чисел k величина $\nu(k)$ мало отличается от $\ln \ln n$.

Точное утверждение дается следующей теоремой:

Теорема. Пусть $w(n) \rightarrow \infty$ произвольно медленно. Тогда количество тех $k \in \{1, 2, \dots, n\}$, для которых $|\nu(k) - \ln \ln n| > w(n)\sqrt{\ln \ln n}$, есть $o(n)$.

Нам понадобится следующее теоретико-числовое утверждение:

Лемма. $\sum_{p \leq n} 1/p = \ln \ln n + O(1)$, где суммирование производится по всем простым числам $p \leq n$.

Доказательство леммы. Сначала вычислим асимптотику суммы $\sum_{p \leq n} \ln p/p$. Для этого разложим на простые множители число $n!$:

$$n! = \prod_{p \leq n} p^{c_p},$$

где произведение берется по простым p и $c_p = [n/p] + [n/p^2] + [n/p^3] + \dots$. Имеем

$$n/p - 1 \leq [n/p] \leq c_p \leq n/p + n/p^2 + \dots = n/(p-1).$$

Подставляя эти значения в выражение для $n!$ и логарифмируя, получаем

$$n \sum \frac{\ln p}{p} - \sum \ln p \leq n! \leq n \sum \frac{\ln p}{(p-1)} = n \sum \frac{\ln p}{p} + n \sum \frac{\ln p}{p(p-1)}$$

(суммирование везде по простым $p \leq n$). Заметим, что $(n/e)^n < n! < n^n$ (левое неравенство устанавливается, например, по индукции). Кроме того, $\prod_{p \leq n} p \leq 4^n$. Это следует из того, что указанное произведение делит $C_n^{n/2} \cdot C_n^{n/4} \cdot C_n^{n/8} \dots$ (подробности, связанные с тем, что n может не быть степенью двойки, опускаются). Наконец, заметим, что $\sum \ln p/(p^2 - p) = O(1)$. Резюмируя получаем, что

$$S_n := \sum_{p \leq n} \frac{\ln p}{p} = \frac{1}{n} \ln n! + O(1) = \ln n + O(1).$$

Выразим интересующую нас сумму $\Sigma_n = \sum_{p \leq n} 1/p$ через S_1, S_2, \dots, S_n . Имеем

$$\Sigma_n = \sum_{p \leq n} 1/p = \sum_{k=1}^n \frac{S_k - S_{k-1}}{\ln k} = \sum_{k=1}^n S_k \left(\frac{1}{\ln k} - \frac{1}{\ln(k+1)} \right) + S_n \ln(n+1).$$

Заметим, что

$$S_k \left(\frac{1}{\ln k} - \frac{1}{\ln(k+1)} \right) = (\ln(k+1) + O(1)) \left(\frac{1}{\ln k} - \frac{1}{\ln(k+1)} \right).$$

Слагаемые типа $O(1)(\frac{1}{\ln k} - \frac{1}{\ln(k+1)})$ дадут в сумме $O(1)$. Также $S_n \ln(n+1) = O(1)$. Далее,

$$\ln(k+1) \left(\frac{1}{\ln k} - \frac{1}{\ln(k+1)} \right) = \frac{\ln(k+1)}{\ln k} - 1 = \ln \frac{\ln(k+1)}{\ln k} + O \left(\left(\frac{\ln(k+1)}{\ln k} - 1 \right)^2 \right),$$

мы воспользовались формулой Тейлора $x - 1 = \ln x + O((x - 1)^2)$, $x \rightarrow 1$. Заметим, что $\ln(k + 1) - \ln(k) = \ln(1 + 1/k) = O(1/k)$, так что $(\frac{\ln(k+1)}{\ln k} - 1)^2 = o(1/k^2)$. Значит, соответствующие поправки $O\left(\left(\frac{\ln(k+1)}{\ln k} - 1\right)^2\right)$ также дадут в сумме $O(1)$.

Итого

$$\Sigma_n = \sum_{k=2}^n \ln \frac{\ln(k+1)}{\ln k} + O(1) = \ln \ln n + O(1).$$

Лемма доказана.

Доказательство теоремы.

Пусть k выбирается в множестве $\{1, 2, \dots, n\}$ согласно равномерному распределению. Определим для каждого простого $p \leq n$ случайную величину X_p как индикатор события $\{k \text{ кратно } p\}$. Тогда $\nu = \sum_p p \leq n X_p$ и требуется доказать, что

$$\mathbb{P}\left(|\nu - \ln \ln n| > w(n)\sqrt{\ln \ln n}\right) \rightarrow 0 \quad (1)$$

Пусть $M = n^{1/5}$ и $\nu_1 = \sum_{p \leq M} X_p$. Заметим, что $\nu_1 \leq \nu \leq \nu_1 + 4$ (так как любое число k от 1 до n имеет не более четырех простых множителей, больших, чем M). Поэтому можно заменить в (1) ν на ν_1 .

Заметим, что

$$E(\nu) = n^{-1} \sum_{p \leq n} [n/p] = \sum_{p < n} 1/p + O(1) = \ln \ln n + O(1)$$

в силу нашей леммы. Таким образом, можно заменить также $\ln \ln n$ на $E\nu_1 = E\nu + O(1)$.

Для оценки $\mathbb{P}(|\nu_1 - E\nu_1| > w(n)\sqrt{\ln \ln n})$ воспользуемся неравенством Чебышева

$$\mathbb{P}\left(|\nu_1 - E\nu_1| > w(n)\sqrt{\ln \ln n}\right) \leq \frac{\text{Var } \nu_1}{w^2(n) \ln \ln n},$$

где Var обозначает дисперсию случайной величины.

Таким образом, достаточно доказать, что $\text{Var} \nu_1 = O(\ln \ln n)$.

Для этого заметим, что

$$\text{Var } \nu_1 = \sum_{p \leq M} \text{Var } X_p + 2 \sum_{p < q \leq M} \text{Cov}(X_p, X_q),$$

где $\text{Cov}(X, Y) = E(X \cdot Y) - E(X) \cdot E(Y)$ обозначает ковариацию случайных величин X и Y . Это равенство получается из формулы $E(X) = E(X^2) - (EX)^2$ путем раскрытия скобок.

Заметим, что $\text{Var } X_p \leq E(X_p)^2 = E(X_p)$, так что первая сумма не превосходит $E(\nu_1) = \ln \ln n + O(1)$.

Оценим $\text{Cov}(X_p, X_q)$:

$$\text{Cov}(X_p, X_q) = \frac{[n/pq]}{n} - \frac{[n/p]}{n} \cdot \frac{[n/q]}{n} \leq \frac{1}{pq} - (1/p - 1/n)(1/q - 1/n) < 1/n(1/p + 1/q) \leq 2/n.$$

Поскольку количество пар различных p, q не превосходит $M^2 < n$, получаем, что сумма ковариаций есть $O(1)$.

Доказательство теоремы завершено.

Использование неравенства Чебышева называется *методом второго момента*.

Приведем пример из теории случайных графов.

Сначала рассмотрим такую ситуацию: имеются случайные величины X_1, X_2, \dots, X_m , являющиеся индикаторами некоторых событий A_1, A_2, \dots, A_m (то есть $X_i = 1$, если происходит событие A_i и $X_i = 0$ в противном случае). Положим $X = \sum X_i$. Как оценить сверху вероятность того, что $X = 0$? Воспользуемся неравенством Чебышева:

$$\mathbf{P}\{X = 0\} \leq \mathbf{P}\{|X - E(X)|^2 \geq E(X)^2\} \leq \frac{\text{Var}(X)}{E(X)^2}. \quad (1)$$

Теперь оценим $\text{Var}(X)$. Будем писать $i \sim j$, если $i \neq j$ и события A_i, A_j не являются независимыми. Имеем

$$\text{Var}(X) = \sum \text{Var}(X_i) + 2 \sum_{i \sim j} \text{Cov}(X_i, X_j) \leq E(X) + 2 \sum_{i \sim j} E(X_i \cdot X_j). \quad (2)$$

Теперь докажем следующее типичное утверждение теории случайных графов:

Теорема. Рассмотрим случайный граф $G(n, p)$ на n вершинах, в котором каждое ребро проводится случайно независимо от других ребер с вероятностью p . Тогда при $p = o(n^{-2/3})$ вероятность наличия в графе $G(n, p)$ клики на четырех вершинах стремится к нулю, а при $p \gg n^{-2/3}$ (то есть $\lim p/n^{-2/3} = +\infty$) вероятность наличия такой клики стремится к бесконечности.

Доказательство. Пронумеруем четверки вершин нашего графа индексом i . Пусть A_i — вероятность того, что вершины i -ой четверки образуют клику, X_i — индикатор события A_i , $X = \sum X_i$. Имеем $E(X) = p^6 \cdot C_n^4$, так что при $p \ll n^{-2/3}$ имеем $E(X) = o(1)$ и вероятность того, что $X \geq 1$ (то есть вероятность наличия клики) стремится к нулю. При $p \gg n^{-2/3}$ имеем $E(X) \rightarrow +\infty$. Докажем, что $\text{Var}(X) = o(E(X)^2)$ — из этого в

силу (1) будет следовать требуемое. Оценим $\text{Var}(X)$ как в (2). Первое слагаемое $E(X)$ есть $o(E(X)^2)$. Оценим сумму $E(X_i X_j) = \mathbb{P}(A_i \cap A_j)$ для всех пар зависимых событий. Для каждого из $O(n^4)$ событий имеется $O(n^2)$ зависимых событий, соответствующих четверкам, пересекающимся по двум вершинам, и $O(n)$ событий, соответствующих четверкам, пересекающимся по трем вершинам. В первом случае вероятность одновременного выполнения событий есть p^{11} , во втором — p^9 . Итак,

$$\sum_{i \sim j} \mathbb{P}(A_i \cap A_j) = O(n^6 p^{11} + n^5 p^9) = o(n^8 p^{12}) = o(E(X)^2),$$

что завершает доказательство.