

# Вероятностный протокол нахождения наибольшего общего начала

18 марта 2017 г.

**Теорема 1** ([1]). Пусть даны  $n$  и  $\delta > 0$ . Существует вероятностный протокол с общими случайными битами и коммуникацией  $O(\log(n/\delta))$ , который для любой пары слов  $(x, y)$  длины  $n$  с вероятностью ошибки не более  $\delta$  находит длину наибольшего общего начала слов  $x, y$ .

*Доказательство.* Алисе и Бобу надо найти номер первого бита, в котором их слова различаются. Это делается бинарным поиском. Для этого они применяют вероятностный протокол для равенства (RET) к словам  $x, y$ . Напомним, что этот протокол имеет параметр  $\varepsilon$ , передает  $\log_2(1/\varepsilon)$  бит, не ошибается на входах, где  $x = y$ , и ошибается с вероятностью не более  $\varepsilon$  на всех остальных парах. Параметр  $\varepsilon$  подберем позднее. Если RET сообщит, что  $x = y$ , то протокол останавливается с результатом  $n$ . Иначе, Алиса и Боб запускают протокол RET на первых половинах своих последовательностей. Если ответ результат будет положительным (первые половины совпадают, то различие надо искать во второй половине, а иначе в первой). После  $\log n$  шагов Алиса и Боб найдут первое различие.

Теперь определим параметр  $\varepsilon$ . Мы запускаем  $\log n$  раз RET и в каждом запуске вероятность ошибки может быть  $\varepsilon$ , поэтому общая вероятность ошибки оценивается сверху как  $\varepsilon \log n$ . Поэтому нам нужно положить  $\varepsilon = \delta / \log n$  и протокол будет передавать  $\log n \log(\log n / \delta)$  бит, что немного больше, чем было обещано.

Сократить количество бит можно следующим приемом. Модифицируем алгоритм бинарного поиска так, чтобы он приводил к правильному ответу при условии, что RET ошибался не более, чем примерно в  $1/4$  запусков. Вспомним, что на каждом шаге этого алгоритма мы имели пару

некоторый подотрезок  $[l, r]$  отрезка  $[1, n + 1]$ , предположительно содержащий первый различающий бит (мы считаем, что этот бит равен  $n + 1$ , если  $x = y$ ). Сначала  $l = 1, r = n + 1$  и за один шаг заменяли либо  $l$  на  $(l + r)/2 + 1$ , либо  $r$  на  $(l + r)/2$ . При этом правая граница всегда правильна, поскольку мы уменьшаем  $r$  до  $(l + r)/2$ , если RET сообщил, что первые половины различаются, а такое сообщение не может быть ошибочным.

В модифицированном алгоритме бинарного поиска мы повторяем  $N$  раз следующую последовательность действий.

- (1) Проверяем равенство  $x_{<l} = y_{<l}$  с помощью теста RET с параметром  $1/8$ . Если он говорит, что равенство неверно, то делаем откат на одну вершину назад в дереве двоичного поиска.
- (2) Если RET говорит, что равенство верно, и при этом мы находимся не в листе дерева поиска (то есть,  $r > l$ ), то действуем, как в обычном алгоритме двоичного поиска.

Предположим, что  $N$  достаточно велико, а количество  $K$  ошибочных ответов теста RET не слишком большое. Докажем, что в этом случае в конце мы будем в правильной вершине дерева поиска. Предположим, что последнее не верно. Заметим, что раз попав в нужный лист дерева  $[l, l]$ , мы никогда уже оттуда не уйдем. В самом деле, в этом случае  $x_{<l} = y_{<l}$ , а тест RET не ошибается в случае равенства. Значит мы ни разу не были в правильной вершине. Нетрудно доказать, что в этом случае (когда мы ни разу не побывали в целевой вершине) следующая величина не увеличивается в ходе каждого выполнения цикла:

$$\begin{aligned}
 & (\text{количество вызовов RET}) \\
 & + 2(\text{расстояние в дереве бинарного поиска} \\
 & \text{цели}) \\
 & - 4(\text{количество ошибочных ответов теста RET}).
 \end{aligned}$$

В самом деле, если в ходе цикла хотя бы раз тест RET дал ошибочный ответ, то последний член уменьшился на 4, первое слагаемое увеличилось не более, чем на 2, и второе, не более, чем на 2. Если же в ходе цикла тест не давал ошибочных ответов, то мы обязательно делаем шаг в правильном направлении, поэтому второй член уменьшается на 2, первый увеличивается не более, чем на 2, а третий не изменяется.

Сначала указанная величина равна  $2 \log n$ , поэтому она никогда не становится больше  $2 \log n$ . При этом в конце протокола она не меньше  $N + 2 - 4K$ . Поэтому мы получим противоречие, если  $N - 4K \geq 2 \log n$ , то есть количество ошибок не превосходит  $N/4 - \log n/2$ .

Теперь нам нужно подобрать  $N$  так, чтобы вероятность события  $K \geq N/4 - \log n/2$  была меньше  $\delta$ . Положим  $N = \max\{8 \log n, C \log(1/\delta)\}$ . Если случилось событие  $K \geq N/4 - \log n/2$ , то  $K/N$  отклонилось от своего среднего значения  $1/8$  не менее, чем на  $(1/4 - 1/16) - 1/8 = 1/16$ . Если  $C$  достаточно велико, то по неравенству Чернова вероятность этого события не больше  $e^{-2(1/16)^2 N} \leq e^{-2(1/16)^2 C \log(1/\delta)} \leq \delta$ .  $\square$

## Список литературы

- [1] U. Feige, D. Peleg, P. Raghavan, and E. Upfal. Computing with noisy information. *SIAM Journal on Computing*, 23(5):1001–1018, 1994.