

Заметки по теории кодирования

Эти заметки были сделаны участниками семинара кафедры математической логики и теории алгоритмов механико-математического факультета МГУ в 2004/5 учебном году, разбиравшими записи лекций М. Судана (Madhu Sudan), прочитанных им в MIT (по выложенным в Internet материалам, см. <http://theory.csail.mit.edu/~madhu>). Рассказывали на семинаре в основном А. Румянцев и А. Ромашенко, текст подготовил к печати А. Шень.

1 Коды с исправлением ошибок: постановка задачи

Пусть Σ — конечный алфавит. Через Σ^n обозначаем множество всех слов длины n в алфавите Σ . *Расстояние Хэмминга* между двумя словами $x_1 \dots x_n$ и $y_1 \dots y_n$ из Σ^n определяется как число позиций, в которых эти слова отличаются (число тех i , при которых $x_i \neq y_i$).

Рассмотрим отображение $F: \Sigma^k \rightarrow \Sigma^n$ при $k < n$ как способ кодирования информации при её передаче. Получив на вход слово $A \in \Sigma^k$, мы передаём по каналу связи слово $F(A)$. В процессе передачи некоторые символы слова $F(A)$ могут быть искажены. Несмотря на это, мы хотим, чтобы было возможно восстановить исходное слово A . Другими словами, мы хотим, чтобы $F(A)$ нельзя было спутать с $F(A')$ даже после того, как некоторые буквы в обоих словах искажены. Если разрешается искажать не более e позиций (в каждом слове), то для однозначного восстановления необходимо и достаточно, чтобы расстояние между $F(A)$ и $F(A')$ было $2e + 1$ или больше.

Более формально, *кодом* называется отображение $F: \Sigma^k \rightarrow \Sigma^n$. Значения этого отображения называются *кодовыми словами*. Минимальное из расстояний $d(F(A), F(A'))$ при $A \neq A'$ называется *минимальным расстоянием* кода F . Код с минимальным расстоянием d позволяет исправлять $e = \lfloor (d-1)/2 \rfloor$ ошибок, поскольку при таком e шары радиуса e с центрами в кодовых словах не пересекаются. (*Шар* радиуса e с центром в слове $x \in \Sigma^n$ определяется как множество всех слов, отличающихся от x не более чем в e позициях. Через $[t]$ обозначается целая часть числа t , то есть наибольшее целое число, не превосходящее t .)

Такая “помехоустойчивость” кода возникает, как говорят, за счёт “из-

быточности” при передаче информации: вместо k символов мы передаём n символов, и $n > k$. Чем больше e и чем ближе k к n , тем лучше код. Конечно, эти два требования противоречат друг другу и одно достигается за счёт другого.

Задачу построения оптимального кода при данных Σ , n и e можно интерпретировать геометрически: в метрическом пространстве Σ^n нужно упаковать без пересечений как можно больше шаров радиуса e . Другой вариант формулировки: требуется найти как можно больше точек с попарными расстояниями $2e + 1$ или больше. После того как шары (их центры) выбраны, можно взять k , равное целой части логарифма числа таких шаров (точек) по основанию $|\Sigma|$ (число букв во входном алфавите), и произвольно сопоставить слова длины k с центрами шаров. (Число k выбрано так, что шаров хватит; часть точек может остаться неиспользованной.)

Выбор этого соответствия (между кодируемыми словами и их кодами) безразличен, пока мы не интересуемся сложностью алгоритмов кодирования и декодирования. Алгоритм кодирования вычисляет функцию F , то есть по входному слову X даёт $F(X)$. Алгоритм декодирования с исправлением e ошибок получает на вход любое слово Y , отстоящее от некоторого кодового слова $F(X)$ на расстояние не больше e , и даёт X на выходе. Естественно, мы хотим, чтобы алгоритмы кодирования и декодирования были не очень сложными и работали быстро.

2 Базовые оценки

При каких значениях параметров $q = |\Sigma|, k, n, e$ код $F: \Sigma^k \rightarrow \Sigma^n$, исправляющий e ошибок, существует, а при каких нет? Две самые простые оценки (с той и другой стороны) таковы:

Граница Хэмминга

Если код с указанными параметрами существует, то

$$q^k V_q(e, n) \leq q^n$$

Здесь через $V_q(e, n)$ обозначается объём (число элементов) шара радиуса e в пространстве слов длины n в алфавите из q букв. (Очевидно, число элементов в шаре не зависит от того, какой у него центр.)

В самом деле, если код существует, то q^k шаров с центрами в кодовых словах помещаются в пространстве из q^n элементов без пересечений.

Логарифмируя, можно переписать границу Хэмминга в таком виде:

$$\frac{k}{n} + \frac{\log_q V_q(e, n)}{n} \leq 1.$$

Первое слагаемое можно назвать “коэффициентом полезного действия” кода.

Эта граница также называется границей Хэмминга, а также “volume bound” (volume — объём).

Граница Гилберта

Если

$$(q^k - 1)V_q(2e, n) < q^n,$$

то существует код с параметрами q, k, n, e .

В самом деле, будем выбирать кодовые слова одно за другим произвольным образом, следя лишь за тем, чтобы расстояния между ними были больше $2e$. Если нового слова выбрать нельзя, это значит, что всё пространство (в котором q^n элементов) полностью покрыто шарами, каждый из которых состоит из $V_q(2e, n)$ элементов. Указанная оценка гарантирует, что при этом имеется как минимум q^k шаров, что и требуется.

Переходя к логарифмам, эту оценку можно записать так:

$$\frac{k}{n} + \frac{\log_q V_q(2e, n)}{n} \leq 1.$$

(для простоты записи мы немного усилили условие и тем самым ослабили утверждение о существовании кода, отбросив вычитание единицы). Это неравенство называют границей Гилберта (а иногда – границей Варшамова–Гилберта). Не следует путать автора этой оценки Эдгара Гилберта (Edgar N. Gilbert) со знаменитым математиком Давидом Гильбертом (David Hilbert).

Размер шара

Обе эти оценки включают в себя число элементов в шаре, поэтому полезно иметь для этого числа хотя бы приближённую формулу. Для случая $q = 2$ число элементов в шаре радиуса s равно сумме биномиальных коэффициентов

$$C_n^0 + C_n^1 + \dots + C_n^s$$

При $s \leq n/2$ (в основном нас интересует этот случай, так как шаров большего радиуса даже и два не поместятся) слагаемые в этой сумме возрастают слева направо и (с точностью до полиномиальных от n множителей) можно ограничиться последним слагаемым. С помощью формулы Стирлинга получаем, что оно (и вся сумма) есть

$$\text{poly}(n)2^{nH(p)}$$

где $p = s/n$, а $H(p)$ — энтропия Шеннона распределения $(p, 1-p)$, которая определяется как

$$H(p) = p \log \frac{1}{p} + (1-p) \log \frac{1}{1-p}.$$

Для произвольного q формула имеет вид

$$V_q(s, n) = \text{poly}(n)q^{nH_q(p)},$$

где $p = s/n$, а

$$H_q(p) = \left[p \log_q \frac{1}{p} + (1-p) \log_q \frac{1}{1-p} \right] + p \log_q (q-1)$$

Здесь квадратная скобка, как и раньше, соответствует выбору не более чем rp позиций, в которых есть отличия (от центра шара), но появляется ещё один член: в каждой из этих rp позиций может стоять любой из $q-1$ символов (не считая теперешнего).

Графики

Полезно изобразить границы Хэмминга и Гилберта на одном графике. По горизонтали будем откладывать кодовое расстояние d (примерно равное $2e$, удвоенному числу исправляемых ошибок) в долях n ; по вертикали — коэффициент полезного действия кода (отношение k/n , где k — число кодируемых символов, а n — длина кода).

Ограничимся случаем $q = 2$ и будем использовать приближённую формулу для объёма шара.

Необходимое условие существование кода, исправляющего e ошибок (граница Хэмминга):

$$\frac{k}{n} + H(e/n) \leq 1 + O(\log n/n)$$

Достаточное условие существования кода с расстоянием не меньше d

$$\frac{k}{n} + H(d/n) \leq 1 - O(\log n/n)$$

Формулы эти похожи, но только d и e отличаются примерно в два раза. Поэтому график для границы Хэмминга получается двукратным растяжением графика для границы Гилberta по горизонтали (рис. 1).

По этой картинке можно определить, скажем, что кода с коэффициентом полезного действия $1/2$ и расстоянием в $n/3$ не существует — соответствующая точка лежит выше границы Хэмминга. С другой стороны, код с коэффициентом полезного действия $1/8$ и расстоянием $n/4$ (и тем самым допускающим исправление $n/8$ ошибок) существует — соответствующая точка лежит ниже границы Гилберта. (Всё сказанное относится к достаточно большим n , так как мы пренебрегали членами порядка $O(\log n/n)$.)

Что происходит между этими границами — один из основных вопросов теории кодирования, до сих пор не решённый полностью (несмотря на множество частичных результатов).

3 Случайные коды

Границу Гилберта можно достичь и другими способами. В этом разделе мы используем для этого случайный код, а в следующем разделе — линейный.

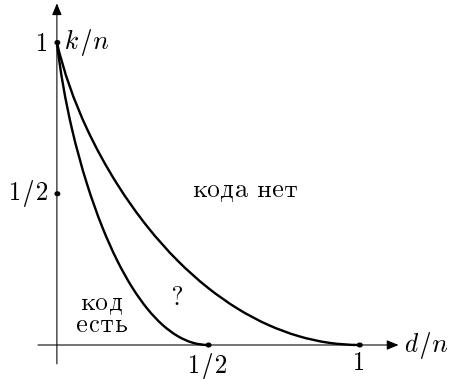


Figure 1: Границы Хэмминга и Гилберта.

Пусть фиксировано некоторое число N . Будем выбирать N кодовых слов ξ_1, \dots, ξ_N случайно среди q^n равновероятных элементов Σ^n . При этом мы считаем все ξ_1, \dots, ξ_n независимыми. (В частности, вероятность совпадения ξ_i и ξ_j при $i \neq j$ отлична от нуля, хотя и мала.)

Для фиксированного $i \in \{1, \dots, N\}$ рассмотрим вероятность того, что в шар радиуса $2e$ с центром ξ_i попадут другие кодовые слова. Вероятность попадания ξ_j с данным j равна $V_q(2e, n)/q^n$ (доле пространства, занимаемой шаром радиуса $2e$); вероятность того, что хотя бы одно ξ_j (при $j \neq i$) попадёт в этот шар, не больше $NV_q(2e, n)/q^n$. Будем называть те i , при которых в шар с центром в ξ_i попали другие ξ_j , “плохими”. Тогда вероятность каждого i оказаться плохим не больше $NV_q(2e, n)/q^n$. Поэтому математическое ожидание числа плохих i не больше $N^2V_q(2e, n)/q^n$, а математическое ожидание доли плохих i (среди всех чисел $1, \dots, N$) — не больше $NV_q(2e, n)/q^n$.

Предположим теперь, что

$$\frac{NV_q(2e, n)}{q^n} \leq 1/2$$

(вдвое меньшее число кодовых слов, чем допускает граница Гилберта). Тогда математическое ожидание доли плохих i не больше $1/2$, и, следовательно, существует вариант, при котором эта доля не больше $1/2$. Задавая один из таких вариантов и выкинув плохие кодовые слова (их не более половины), мы получим код с расстоянием не менее $2e + 1$, который всего лишь в четыре раза хуже (по числу слов — мы начали с вдвое меньшего числа, да ещё отбросили половину), чем построенный ранее.

4 Линейные коды

Если q есть степень простого числа, то (как известно из алгебры) существует поле \mathbb{F}_q из q элементов. В этом случае можно считать, что $\Sigma = \mathbb{F}_q$, а слова образуют векторное пространство (размерности n или k) над \mathbb{F}_q . В этой ситуации возникает понятие *линейного* кода. Такой код представляет собой линейное (над \mathbb{F}_q) отображение $\mathbb{F}_q^k \rightarrow \mathbb{F}_q^n$. Это отображение задаётся матрицей размера $n \times k$, элементы которой принадлежат полю \mathbb{F}_q .

Множество всех кодовых слов линейного кода (образ этого отображения) представляет собой подпространство в \mathbb{F}_q^n . В силу линейности окрестности всех кодовых слов устроены одинаково (отличаются сдвигом). Поэтому кодовое расстояние линейного кода можно измерять в любой точке, в частности, в нуле: оно равно минимально возможному числу ненулевых координат в ненулевом кодовом слове.

Таким образом, для построения линейного кода с расстоянием больше $2e$ достаточно указать k -мерное подпространство C в пространстве \mathbb{F}_q^n , все векторы которого содержат более $2e$ ненулевых координат (не попадают в шар радиуса $2e$ с центром в нуле). (Само кодовое отображение $\mathbb{F}_q^k \rightarrow C$ после этого можно выбрать любым, лишь бы оно было изоморфизмом линейных пространств.)

Чтобы построить искомый линейный код, будем добавлять в базис подпространства C вектор за вектором, следя за тем, чтобы кодовое расстояние оставалось больше $2e$. Пусть уже есть s базисных векторов, которые порождают некоторое подпространство. Новый (добавляемый) базисный вектор должен быть на расстоянии более $2e$ от всех векторов подпространства; это, как легко понять, гарантирует, что и после его добавления расстояние между любыми двумя векторами останется больше $2e$. Другими словами, новый вектор должен лежать вне объединения 2^s шаров радиуса $2e$.

Таким образом, для получения k -мерного подпространства достаточно выполнения неравенства

$$q^{k-1}V_q(2e, n) < q^n$$

Эту оценку называют границей Варшамова–Гилберта. Она чуть лучше оценки в границе Гилберта (там было $q^k - 1$, а теперь q^{k-1}), но это рассуждение годится лишь при некоторых q (степенях простых чисел). При стремлении n бесконечности оценки Гилбрета и Варшамова–Гилберта дают одинаковые асимптотические оценки для отношения k/n .

Заметим, что в случае линейного кода кодирование выполняется легко (умножение на матрицу кода), но про декодирование по-прежнему ничего хорошего сказать нельзя (хотя для некоторых линейных кодов, как мы увидим, существуют быстрые алгоритмы декодирования).

Линейное подпространство размерности k в пространстве \mathbb{F}_q^n можно задавать не только как образ линейного оператора $\mathbb{F}_q^k \rightarrow \mathbb{F}_q^n$, но и как ядро оператора $\mathbb{F}_q^n \rightarrow \mathbb{F}_q^{n-k}$, имеющего максимальный ранг $(n - k)$. Такой оператор задаётся матрицей T из $n - k$ строк и n столбцов. Вектор-столбец

x высоты n является кодовым словом тогда и только тогда, когда $Tx = 0$ ($n - k$ уравнений с n переменными). Эта матрица называется *проверочной*, поскольку умножением на неё проверяется принадлежность множеству кодовых слов. Код с проверочной матрицей T имеет расстояние d тогда и только тогда, когда любые $d - 1$ столбцов матрицы T линейно независимы. В самом деле, кодовое слово, в котором лишь $d - 1$ позиций отличны от нуля, как раз и выражает линейную зависимость между $d - 1$ столбцами проверочной матрицы.

5 Код Хэмминга

Сейчас мы рассмотрим случай, когда удаётся указать простой код с наилучшими возможными параметрами (шары плотно заполняют всё пространство, достигая границы Хэмминга). Этот код называется *кодом Хэмминга* и позволяет исправлять одну ошибку, то есть имеет минимальное расстояние 3.

Рассмотрим алфавит из двух букв $\mathbb{B} = \{0, 1\}$. Мы будем рассматривать его как поле из двух элементов со сложением (\oplus) и умножением по модулю 2.

В пространстве \mathbb{B}^n шар радиуса 1 состоит из $n + 1$ элементов (центр и ещё n слов, отличающихся от центрального в одной из n позиций). Всего слов 2^n , поэтому шансы на укладку шаров без пробелов и перекрытий есть, лишь если 2^n кратно $n + 1$, то есть если $n + 1$ есть степень двойки: $n = 2^s - 1$ для некоторого целого s (при $n = 3, 7, 15, 31, \dots$; случай $n = 1$ тривиален).

При $n = 3$ есть 8 вершин куба, которые разбиваются на два шара с центрами в противоположных вершинах. Каждый из шаров содержит 4 элемента, так что плотная упаковка действительно возможна.

Оказывается, что она возможна и при остальных значениях n из указанной серии. Чтобы убедиться в этом, рассмотрим произвольное $n = 2^s - 1$ и запишем все числа от 1 до n в двоичной системе по строкам матрицы. Например, при $n = 7$ получится матрица

$$\begin{matrix} 0 & 0 & 1 \\ 0 & 1 & 0 \\ 0 & 1 & 1 \\ 1 & 0 & 0 \\ 1 & 0 & 1 \\ 1 & 1 & 0 \\ 1 & 1 & 1 \end{matrix}$$

Столбцы этой матрицы будем рассматривать как способы вычисления “контрольных битов”. А именно, пусть

$$x_1, x_2, x_3, x_4, x_5, x_6, x_7$$

— произвольное слово из \mathbb{B}^7 . Для него мы вычислим три контрольных суммы, складывая по модулю 2 те биты, против которых в матрице стоит

единица: $x_4 \oplus x_5 \oplus x_6 \oplus x_7$ (для первого столбца), $x_2 \oplus x_3 \oplus x_6 \oplus x_7$ (для второго столбца) и $x_1 \oplus x_3 \oplus x_5 \oplus x_7$ (для третьего столбца).

Можно сказать, что мы умножаем строку (x_1, \dots, x_7) на эту матрицу, получая строку из трёх контрольных сумм.

Кодовые слова (центры шаров) — это те строки длины 7, для которых все три контрольные суммы равны нулю. Линейная алгебра говорит, что они образуют подпространство размерности 4 (три уравнения на семь переменных; легко проверить, что уравнения независимы, посмотрев на первую, вторую и четвёртую строки), состоящее из $2^4 = 16$ кодовых слов. Это в точности соответствует определению линейного кода с помощью проверочной матрицы, только матрица транспонирована.

Что случится с контрольными суммами, если мы отойдём от центра шара на единицу, то есть изменим какой-либо из битов x_i ? Изменятся (станут равными единице) те контрольные суммы, в которые этот бит входит, то есть те, где в i -й строке матрицы стоит единица. При этом контрольные суммы образуют как раз двоичную запись числа i , поскольку так устроена матрица. Таким образом, по этим контрольным суммам мы восстановим, какой бит изменился, и сможем изменить его на противоположный.

Мы описали алгоритм декодирования, исправляющий ошибку в любом (но только одном) бите. Отсюда автоматически следует, что шары не пересекаются. Тем самым у нас есть 16 шаров, каждый из которых состоит из 8 элементов, и вместе они покрывают все 128 элементов семимерного булева куба \mathbb{B}^7 .

Точно так же для произвольных s и $n = 2^s - 1$ строится матрица из n строк длины s (двоичные записи чисел $1, \dots, n$). Её столбцы указывают s контрольных сумм для векторов из \mathbb{B}^n . Кодовых слов 2^{n-s} , в каждом шаре $n+1 = 2^s$ элементов и они покрывают \mathbb{B}^n полностью.

Заметим, что этот код не только *совершенный* (всё пространство занято шарами без пробелов), но и имеет простые алгоритмы кодирования и декодирования. Единственный его недостаток — что он исправляет только одну ошибку.

Замечания.

1. Можно вычеркнуть из матрицы часть строк. При этом мы получим код с тем же числом контрольных сумм, но с меньшим числом битов. Он уже не будет совершенным, но будет достаточно эффективным. (Больше половины строк выкидывать нет смысла, поскольку тогда уж лучше уменьшить ширину матрицы. А если мы выбрасываем меньше половины строк, то теряем не больше половины места.)

2. Аналогичное построение возможно и при $q > 2$, если существует поле \mathbb{F}_q из q элементов (это бывает, когда q есть степень простого числа). Для этого напишем в строках матрицы ненулевые векторы из \mathbb{F}_q^s , причём из каждого класса пропорциональных друг другу векторов оставим только один. Всего ненулевых векторов $q^s - 1$, в каждом классе $q - 1$ пропорциональных друг другу векторов, так что классов (и строк матрицы) будет $n = (q^s - 1)/(q - 1)$. Ясно, что ранг полученной матрицы равен s .

Изменение одной позиции в кодовом слове изменит контрольные суммы

на вектор, пропорциональный одной из строк матрицы, и по построению эта строка (и тем самым номер изменённого бита) определится однозначно.

Кодовых слов будет q^{n-s} , размер шара $1+n(q-1)$ (в каждой из n позиций можно заменить букву на $(q-1)$ других, да ещё центр шара), что равно

$$1 + \frac{q^s - 1}{q-1}(q-1) = q^s.$$

Таким образом, шары заполняют всё пространство.

3. Для доказательства того, что код Хэмминга имеет расстояние не меньше 3, достаточно было бы сослаться на то, что любые две строки в нашей матрице (=любые два столбца в проверочной матрице из предыдущего раздела) линейно независимы. Но нам важен и простой алгоритм декодирования.

6 Неравенство Синглетона

Для любого кода $F: \Sigma^k \rightarrow \Sigma^n$ с расстоянием d выполняется *неравенство Синглетона*

$$d \leq n - k + 1$$

В самом деле, пусть имеется q^k кодовых слов в Σ^n . Выделим в этих словах первые $k-1$ позиций. Для некоторой пары кодовых слов эти $k-1$ позиций совпадают по принципу Дирихле (число слов q^k больше числа вариантов q^{k-1}). Расстояние между такими словами не больше $n-(k-1)=n-k+1$, что и требовалось доказать.

Для кодов в двухбуквенном алфавите эта оценка уступает оценке Хэмминга. А именно, для кода с расстоянием d она оценивает сверху коэффициент полезного действия кода (отношение k/n , называемое также *скоростью кода*) величиной $1-d/n$, что на графике рис. 1 соответствует прямой, соединяющей точки $(0, 1)$ и $(1, 0)$. Видно, что эта прямая соединяет концы кривой Хэмминга и лежит выше неё.

Для большего размера алфавита это уже не так. Дело в том, что оценка Хэмминга не даёт ничего хорошего при $d \approx n$. Рассмотрим, например, случай $q=3$ и шар радиуса $n/2$ или чуть меньше. Сколько элементов в этом шаре? Позиций несовпадения примерно $n/2$ среди n ; вариантов выбора не более 2^n . После такого выбора останется выбрать в каждой позиции несовпадения один из двух несовпадающих символов, получится не более $2^{n/2}$. Таким образом, шар радиуса не более $n/2$ содержит не более $2^{3n/2} = (2\sqrt{2})^n$ элементов. А всего в пространстве 3^n точек, поэтому оценка на число шаров будет всего лишь $(3/2\sqrt{2})^n$ и кривая Хэмминга не стремится к нулю при $d \approx n$ (в отличие от прямой Синглетона).

7 Код Рида – Соломона

Рассмотрим конечное поле \mathbb{F}_q из q элементов (из алгебры известно, что это возможно, когда q есть степень простого числа).

Кодируемое слово $a_0a_1\dots a_{k-1}$ (где $a_i \in \Sigma = \mathbb{F}_q$) будем рассматривать как последовательность коэффициентов многочлена

$$A(x) = a_0 + a_1x + \dots + a_{k-1}x^{k-1}$$

степени меньше k . Ему соответствует кодовое слово, состоящее из значений многочлена A в n заранее выбранных точках поля \mathbb{F}_q (естественно, что для этого надо, чтобы $n \leq q$). Из курса алгебры известно, что два различных многочлена степени меньше k могут совпадать максимум в $k - 1$ точках. Поэтому для различных многочленов имеется как минимум $n - k + 1$ точек (среди выбранных нами n) несовпадения, то есть кодовое расстояние не меньше $n - k + 1$. Тем самым для кодов Рида – Соломона неравенство Синглетона обращается в равенство.

Кодирование выполняется просто. Некоторая проблема тут с декодированием: как восстановить многочлен по таблице значений, где некоторые значения испорчены? Оказывается, что это можно сделать за полиномиальное время (чего с первого взгляда не скажешь).

8 Декодирование кодов Рида – Соломона

Итак, пусть имеется таблица значений многочлена P степени меньше k в некоторых n точках, причём $e = \lfloor (n - k)/2 \rfloor$ значений в ней могут быть неверными. (Такое значение e соответствует числу исправляемых ошибок при кодовом расстоянии $d = n - k + 1$.) Другими словами, нам дана искажённая функция \tilde{P} , определённая в n точках и отличающаяся от неизвестного нам многочлена P не более чем в e точках. Как найти P ?

Поскольку число ошибок не больше e , существует (пока что неизвестный нам) многочлен $D(x)$ степени e , который обращается в нуль в местах ошибок. Тогда $P(x)D(x)$ равно $\tilde{P}(x)D(x)$ во всех n точках, поскольку разница между $P(x)$ и $\tilde{P}(x)$ приходится на те x , где $D(x) = 0$. Многочлен $Q(x) = P(x)D(x)$ имеет степень меньше $k + e$. Таким образом, верна

Лемма 1. Существуют многочлены $D(x)$ степени e и $Q(x)$ степени менее $k + e$, для которых $\tilde{P}(x)D(x) = Q(x)$ для всех n точек.

Удобно договориться, что старший коэффициент многочлена D (при x^e) равен единице. Тогда лемму 1 можно считать утверждением о разрешимости некоторой системы линейных уравнений. Неизвестными в ней являются остальные e коэффициентов многочлена D и $k + e$ коэффициентов многочлена Q (всего $k + 2e$ штук), а уравнений в ней n (что не меньше $k + 2e$, хотя нам это и не важно).

Тем самым некоторые многочлены, удовлетворяющие условиям леммы 1, можно найти, решив эту систему. Правда, пока мы не знаем, как они связаны с “настоящими” D и Q . Об этом говорит

Лемма 2. Пусть $\tilde{D}(x)$ и $\tilde{Q}(x)$ — произвольные многочлены, удовлетворяющие условиям леммы 1 (это значит, что они имеют нужные степени и равенство $\tilde{P}(x)\tilde{D}(x) = \tilde{Q}(x)$ выполняется во всех n точках). Тогда

(а) \tilde{Q} делится на \tilde{D} в кольце многочленов $\mathbb{F}_q[x]$;

(6) частное \tilde{Q}/\tilde{D} равно исходному (и искомому) многочлену P .

Доказательство. Многочлены $P\tilde{D}$ и \tilde{Q} имеют степень меньше $k + e$. Они совпадают во всех тех точках, где $P = \tilde{P}$, а таких точек как минимум $n - e \geq k + e$, поэтому эти многочлены равны.

Таким образом, мы получили алгоритм декодирования кодов Рида – Соломона. Оба его этапа — и решение системы линейных уравнений, и деление многочленов, — выполняются за время, полиномиальное от n и $\log q$.

Замечание 1. Это утверждение требует некоторых пояснений. Дело в том, что поле \mathbb{F}_q — вещь абстрактная. Оно единственno с точностью до изоморфизма, но не имеет какого-то “канонического” представления. Можно доказать, что его элементы можно представить числами $0 \dots q - 1$ таким образом, что операции сложения, вычитания, умножения и деления выполняются за полиномиальное от $\log q$ время. При использовании такого представления алгоритм декодирования и будет полиномиальным от n и $\log q$.

Замечание 2. Можно рассматривать также задачу о декодировании с ошибками и пропусками. Под *пропуском* мы понимаем позицию, в которой буква неизвестна. (Это лучше, чем неверная буква, так как мы хотя бы знаем, в какой позиции проблема.) Видно, что для декодирования кода Рида – Соломона нужно, чтобы число пропусков плюс удвоенное число ошибок не превосходило $n - k$ (поскольку пропуск одной позиции даёт снова код Рида – Соломона с заменой n на $n - 1$). Так что пропуск считается за пол-ошибки (“два переезда — как один пожар”).

Всем хороши эти коды, но только они требуют достаточно большого алфавита (размер алфавита должен быть не меньше длины кодовых слов, да ещё быть степенью простого числа). Уменьшить алфавит можно, используя конструкцию каскадных кодов, описываемую в следующем разделе.

9 Каскадные коды

Пусть имеется некоторый код с большим алфавитом Σ . Можно ли его переделать в код с меньшим (скажем, двоичным) алфавитом? Например, пусть Σ содержит 2^s букв. Тогда можно записать каждую букву из Σ с помощью блока из s битов. При этом код $\Sigma^k \rightarrow \Sigma^n$ превратится в код $\mathbb{B}^{sk} \rightarrow \mathbb{B}^{sn}$.

Кодовое расстояние при этом не уменьшится. В самом деле, если для исходного кода оно было d , то теперь два кодовых слова отличаются по крайней мере в d блоках, а отличие в блоке означает отличие хотя бы в одном бите этого блока.

Общая длина кодовых слов, однако, возрастёт (в s раз), так что допустимый процент ошибок в кодовом слове уменьшится в s раз.

Более надёжный двоичный код получится, если кодировать буквы алфавита Σ блоками не из s битов, а из большего числа битов, причём использовать при этом какой-либо код, исправляющий ошибки.

В общем случае такая конструкция “каскадного кода”, или “конкатенации” двух кодов, применима к кодам

$$F_1: \Sigma_1^{k_1} \rightarrow \Sigma_1^{n_1} \quad \text{и} \quad F_2: \Sigma_2^{k_2} \rightarrow \Sigma_2^{n_2},$$

если $|\Sigma_1| = |\Sigma_2|^{k_2}$. Тогда каждую букву алфавита Σ_1 можно рассматривать как блок из k_2 символов алфавита Σ_2 и кодировать блоком из n_2 символов алфавита Σ_2 .

Формально, определим *конкатенацию* “внешнего” кода F_1 и “внутреннего” кода F_2 как код

$$F: \Sigma_2^{k_1 k_2} \rightarrow \Sigma_2^{n_1 n_2}$$

Чтобы найти значение F на слове длины $k_1 k_2$, составленном из букв алфавита Σ_2 , это слово надо разбить на k_1 блоков длиной k_2 . Если эти блоки считать буквами алфавита Σ_1 , получится слово длиной k_1 в алфавите Σ_1 . Применив к нему код F_1 , получим слово из n_1 блоков длины k_2 . Остается закодировать каждый из этих блоков по отдельности кодом F_2 , получив n_1 блоков длиной n_2 , или всего $n_1 n_2$ букв алфавита Σ_2 .

Теорема. Кодовое расстояние конкатенации кодов не меньше произведения их кодовых расстояний.

В самом деле, рассмотрим два различных кодовых слова в конкатенации. Каждое из них состоит из n_1 блоков длиной n_2 . Условие на код F_1 гарантирует, что имеется по крайней мере d_1 различных блоков. Условие на код F_2 гарантирует, что в каждой паре различных блоков имеется (как минимум) d_2 различных букв, всего получается $d_1 d_2$ различий.

Таким образом, каскадный код позволяет исправлять (примерно) $d_1 d_2 / 2$ ошибок (половина кодового расстояния). Но как именно это сделать?

10 Декодирование каскадных кодов

Пусть код F является конкатенацией кодов F_1 и F_2 . Имея алгоритмы декодирования для F_1 и F_2 , можно предложить следующий естественный алгоритм декодирования для F : декодировать каждый блок с помощью F_2 -декодирования, а к полученному слову применить F_1 -декодирование. Чтобы этот алгоритм работал, в декодируемом слове должно быть не более e_1 блоков с более чем e_2 ошибками (где e_1 и e_2 — допустимые числа ошибок для кодов F_1 и F_2). Это заведомо будет так, если общее число ошибок (во всех блоках) не больше $e_1 e_2$. Учитывая, что $e_i \approx d_i / 2$, мы видим, что такой алгоритм позволяет исправлять примерно $d_1 d_2 / 4$ ошибок, что составляет четверть кодового расстояния и вдвое меньше максимально допустимого числа ошибок (которое примерно равно половине кодового расстояния).

Более устойчивый к ошибкам (и тем не менее достаточно эффективный) алгоритм декодирования возможен, если в качестве внешнего кода (как часто бывает) применяется код Рида – Соломона. Или любой другой код, который позволяет эффективно декодировать слова с ошибками и пропусками, причём пропуск считается за пол-ошибки. В этом случае удаётся

исправлять до $d_1 e_2$ ошибок (что соответствует приведённой выше оценке для минимального расстояния каскадного кода).

Делается это так. Код F_2 позволяет исправлять $e_2 = \lfloor (d_2 - 1)/2 \rfloor$ ошибок. Пусть дан некоторый “порог” t в диапазоне $0 \dots e_2$. (Как его выбирать, мы обсудим дальше.) Получив для декодирования n_1 блоков по n_2 символов в каждом, мы применяем алгоритм F_2 -декодирования к каждому блоку в отдельности, а затем для проверки применяем алгоритм кодирования и смотрим, в скольких позициях есть отличие. Если полученное кодовое слово отличается от исходного блока более чем в e_2 позициях (а также если алгоритм декодирования вообще не дал результата), то этот блок объявляется “неизвестным”. Более того, если число отличий в блоке больше порога t , то блок также объявляется неизвестным. Результаты декодирования остальных (“известных”) блоков вместе с информацией о том, какие блоки неизвестны, подаются на вход алгоритма декодирования кода F_1 — который, по предположению, умеет работать с u пропусками и v ошибками, если $u + 2v < d_1$.

Лемма. Если общее число ошибочных позиций (среди $n_1 n_2$ поданных на вход описанного алгоритма) меньше $d_1 e_2$, то описанный процесс позволяет правильно декодировать исходное слово хотя бы при одном значении параметра t .

Прежде чем доказывать лемму, заметим, что она не говорит, как найти хорошее значение параметра t — но это и не нужно. Мы можем перепроверять все значения (их число заведомо не превосходит n , поэтому этот перебор не повредит полиномиальности алгоритма) и затем проверить полученные результаты с помощью кодирования (правильный должен давать менее $d_1 d_2 / 2$ отличий).

Осталось доказать лемму. Предположим, что некоторое t выбрано. Пусть ε_i — истинное число ошибок в i -м блоке (при $i = 1, 2, \dots, n_1$). Числа ε_i нам неизвестны, но мы знаем, что:

- если $\varepsilon_i \leq t$, то i -й блок декодирован правильно (и сочтён известным);
- если $t < \varepsilon_i < d_2 - t$, то i -й блок объявлен неизвестным (мы не могли принять его за другой блок и счесть известным, так как если расстояние до другого центра шара не больше t , то расстояние до нашего центра не меньше $d_2 - t$ по неравенству треугольника);
- наконец, если $\varepsilon_i \geq d_2 - t$, то с i -м блоком может быть всякое (он может быть сочтён неизвестным или быть принят за другой блок).

Таким образом, для данного t все индексы $i = 1, 2, \dots, n_1$ делятся на три категории (задаваемые тремя указанными неравенствами на ε_i). Количество таких индексов обозначим через $\alpha(t)$, $\beta(t)$ и $\gamma(t)$ соответственно. Нам достаточно доказать, что при некотором t (из промежутка $0 \dots e_2$) выполняется неравенство $\beta(t) + 2\gamma(t) < d_1$. (Реальная ситуация может быть даже немного лучше, если блок с большим числом ошибок не был принят за другой блок, а был сочтён неизвестным.)

Чтобы доказать существование такого значения t , достаточно установить, что среднее значение величины $\beta(t) + 2\gamma(t)$ меньше d_1 . При усреднении мы считаем все значения t от 0 до e_2 равновероятными, то есть речь

идёт просто о среднем арифметическом. А кодируемое слово, его код и внесённые в него ошибки (тем самым, и числа ε_i) мы считаем фиксированными.

В силу аддитивности математического ожидания (линейности среднего арифметического) можно вычислить средний вклад каждого отдельного i , а потом сложить их по всем i . Итак, пусть фиксировано некоторое i (и тем самым значение ε_i).

- Если $\varepsilon_i \leq e_2$, то в третью категорию мы попасть не можем, а во вторую попадём, когда $t < \varepsilon_i$. Вероятность этого события (она же — вклад i в интересующее нас среднее) есть $\varepsilon_i/(e_2 + 1)$.
- Если $\varepsilon_i > e_2$, то мы попадём либо во вторую категорию, либо в третью — последнее случится, если $t \geq d_2 - \varepsilon_i$. Вероятность этого события равна

$$\frac{(e_2 + 1) - (d_2 - \varepsilon_i)}{e_2 + 1},$$

поэтому матожидание вклада позиции i в $\beta + 2\gamma$ не превосходит

$$1 + \frac{e_2 + 1 - d_2 + \varepsilon_i}{e_2 + 1} = \frac{2e_2 + 2 - d_2 + \varepsilon_i}{e_2 + 1} \leq \frac{\varepsilon_i + 1}{e_2 + 1} < \frac{\varepsilon_i}{e_2}$$

(мы использовали при оценке, что $2e_2 + 1 \leq d_2$: таково соотношение между числом исправляемых ошибок и кодовым расстоянием для внутреннего кода).

Заметим, что полученная только что оценка верна (хотя и тривиальна) при $\varepsilon > d_2$.

Таким образом, среднее в обоих случаях не превосходит ε_i/e_2 для данного i и $(\sum \varepsilon_i)/e_2$ в сумме. Что по предположению леммы меньше d_1 (ведь $\sum \varepsilon_i$ есть общее число ошибок в кодовом слове каскадного кода).

Лемма доказана.

11 Теорема Форни

Будем рассматривать двоичные коды с возрастающей длиной кодового слова и требовать, чтобы доля исправляемых ошибок (e/n в наших обозначениях) и коэффициент полезного действия кода (k/n в наших обозначениях) были отделены от нуля.

Существование таких кодов очевидно следует из оценки Варшамова — Гилберта. Но если мы хотим, чтобы алгоритмы кодирования и декодирования были бы достаточно эффективны (скажем, полиномиальны по n , длине кодового слова), требуется более сложная конструкция.

В двух словах эта конструкция (предложенная Форни в середине 1960-х годов) такова: рассмотрим конкатенацию двух кодов, причём внешним является код Рида — Соломона, а внутренний ищется перебором кодовых слов, как в доказательстве оценки Варшамова — Гилберта. Если внутренний код имеет длину кодового слова $O(\log n)$, то его поиск и алгоритмы кодирования/декодирования будут экспоненциальными от $\log n$, но полиномиальными по n .

Более подробно. При построении каскадного кода коэффициенты полезного действия перемножаются, как и доли исправляемых ошибок (даже если не использовать улучшенный алгоритм декодирования из предыдущего раздела). Поэтому нам нужно всего лишь, чтобы для каждого из них коэффициент полезного действия и доля исправляемых ошибок были отделены от нуля.

Для наглядности возьмём какой-нибудь пример с конкретными значениями параметров. Фиксируем натуральное k и рассмотрим поле \mathbb{F} из 2^k элементов. Кодируемое слово будет состоять из 2^{k-1} блоков (число блоков — половина размера поля). Каждый блок содержит k битов, то есть представляет собой элемент поля \mathbb{F} . Мы считаем блоки коэффициентами многочлена степени меньше 2^{k-1} . Внешним кодом является код Рида – Соломона: от коэффициентов этого многочлена мы переходим к его значениям во всех 2^k точках поля. При этом число блоков удваивается.

Далее мы кодируем по отдельности каждый блок с помощью внутреннего кода. Будем считать, что при кодировании блок удлиняется вдвое (из k битов получается $2k$). Граница Варшамова – Гилберта (рис. 1 на с. 5) показывает, что при этом можно добиться кодового расстояния 10% (от длины кодового слова, в данном случае $2k$) и исправления 5% ошибок.

В итоге конкатенация кодов увеличивает число битов в 4 раза и имеет кодовое расстояние 5% (от длины слова). При этом тривиальный алгоритм декодирования позволяет исправлять 1,25% ошибок, а улучшенный — 2,5%.

Осталось оценить сложность алгоритмов кодирования и декодирования. Элементы поля из 2^k элементов можно представить k -битовыми строками. Вспомним построение этого поля, известное из курса алгебры. Оно есть кольцо многочленов $\mathbb{F}_2[t]$, профакторизованное по неприводимому многочлену степени k . (Здесь $\mathbb{F}_2 = \{0, 1\}$ — поле из двух элементов.) Как найти этот неприводимый многочлен? Сейчас у нас большой запас времени и можно просто испробовать все многочлены степени k , проверяя их неприводимость с помощью алгоритма Берлекэмпа. Таких многочленов 2^k , и эта процедура будет полиномиальной по длине кодируемого слова, равной $k2^{k-1}$. После отыскания такого многочлена операции в поле выполняются за полиномиальное от k время (что даже лучше, чем нужно). Так что единственная сложная операция — это поиск кода, выполняемый при доказательстве оценки Варшамова – Гилберта. Но и он полиномиален по 2^k (по крайней мере в двух доказательствах из трёх приведённых нами — не годится доказательство со случайным кодом, так как там вероятностное пространство имеет размер двойной экспоненты).

Декодирование внутреннего кода при этом происходит с помощью перебора всех кодовых слов внутреннего кода (что допустимо, так как их не более 2^k).

12 Код Форни – Возенкрафта – Юстесена

Интересная модификация конструкции Форни (см. предыдущий раздел) была предложена Юстесеном. Её идея в том, что мы не обязаны использовать один и тот же внутренний код для всех блоков. Более того, если для некоторой малой части блоков мы выберем неудачный внутренний код, это тоже не страшно (хотя и приведёт к некоторому уменьшению кодового расстояния конкатенации).

Оказывается, что можно (следуя Возенкрафту) предложить очень простое семейство кодов, большинство из которых хорошие. А именно, пусть \mathbb{F} — поле из 2^k элементов, представленных k -битовыми строками. Для каждого $\alpha \in \mathbb{F}$ рассмотрим код

$$C_\alpha : x \mapsto (x, \alpha \cdot x)$$

(к произвольным k битам дописываются ещё k битов, получаемые из первых умножением на α в смысле поля \mathbb{F}). Мы будем считать, что сложение в поле \mathbb{F} соответствует побитовому сложению строк по модулю 2. (Именно так и получается при построении поля как факторкольца.) Тогда код C_α является линейным (для любого элемента $\alpha \in \mathbb{F}$).

Не всегда код C_α хорош. Например, при $\alpha = 0$ мы дописываем нули, что совсем бессмысленно; при $\alpha = 1$ мы дублируем каждый бит слова x , что тоже ничего хорошего не даёт. Но оказывается, что при малых $\varepsilon > 0$ доля тех $\alpha \in \mathbb{F}$, при которых кодовое расстояние кода C_α больше εk , близка к единице. Это следует из такой леммы:

Лемма Возенкрафта. Доля тех $\alpha \in \mathbb{F}$, при которых код C_α имеет кодовое расстояние не более s , не превосходит

$$\frac{V_2(s, k)^2}{2^k}.$$

Поскольку $V_2(s, k) \approx 2^{kH(s/k)}$, при малых s/k это отношение, примерно равное $2^{(2H(s/k)-1)k}$, близко к нулю.

Доказательство леммы Возенкрафта совсем просто. Пусть кодовое расстояние для C_α не больше s . Поскольку код линеен, это значит, что найдётся такое ненулевое слово x , при котором общее количество единиц в битовых строках x и αx не больше s . В частности, слова x и αx находятся в шаре радиуса s с центром в нуле. Тогда коэффициент α представим в виде дроби, числитель и знаменатель которой лежат в указанном шаре, а таких дробей не больше, чем квадрат числа элементов шара, то есть $V_2(s, k)^2$. А всего в поле \mathbb{F} имеется 2^k элементов, что и даёт указанную оценку.

Теперь можно построить каскадный код, используя для внутреннего кодирования коды C_α . Конкретно это выглядит так. Как и в конструкции Форни, мы начинаем с 2^{k-1} блоков длины k , рассматривая блоки как элементы поля \mathbb{F} . Эти элементы мы считаем коэффициентами некоторого многочлена P степени менее 2^{k-1} . Затем мы берём значения многочлена P

во всех точках $x \in \mathbb{F}$ и подвергаем их внутреннему кодированию. В данном случае к значению $P(x)$ мы применяем код C_x , то есть рассматриваем пару

$$(P(x), xP(x))$$

как слово длины $2k$. Все эти слова вместе и образуют кодовое слово длины $2k2^k$.

Этот код имеет коэффициент полезного действия 25% (удлиняет слова в четыре раза). Кодовое расстояние этого кода (делённое на длину кодового слова, то есть в расчёте на один символ) отделено от нуля, как и в конструкции Форни.

Это можно доказать примерно так: при некотором $\varepsilon > 0$ доля тех $x \in \mathbb{F}$, при которых кодовое расстояние кода C_x (в расчёте на символ) меньше ε , не превосходит 1%. А один процент блоков внешнего кода не может сильно повлиять на его кодовое расстояние.

Замечания.

1. При этой конструкции построение кода и кодирование не требуют перебора. Однако декодирование внутреннего кода (в тех блоках, где оно удаётся) по-прежнему требует перебора всех возможных кодовых слов.

2. Построенный код легко описать безо всякого упоминания о конкатенации. В самом деле, мы делаем всё как в кодах Рида – Соломона, только берём значения (во всех точках поля) не одного многочлена $P(x)$, а двух: многочлена $P(x)$ и многочлена $xP(x)$. Другими словами, мы записываем данный нам набор элементов поля в коэффициенты многочленов дважды — начиная со свободного члена и начиная с первой степени, — и объединяем полученные значения.

Было бы интересно доказать, что получается хороший код, не ссылаясь на каскадное кодирование. [А может быть, и простой код Рида – Соломона тоже бы сгодился, просто надо взять побольше точек, и это заменит второй многочлен?]

13 Оценка Плоткина

Различие между границами Хэмминга и Гилберта особенно разительно в правой половине рис. 1: при $d > n/2$ граница Хэмминга не запрещает существования кодов, а граница Гилберта не гарантирует их существования. Что же происходит на самом деле? (Речь идёт о двоичных кодах, когда $\Sigma = \{0, 1\}$.)

Максимальное расстояние между двумя элементами \mathbb{B}^n равно n . Точки, между которыми такое расстояние, отличаются во всех позициях, и потому ясно, что три точки с попарными расстояниями n найти нельзя. Более того, даже если ослабить требования и искать три точки с попарными расстояниями не меньше $0,99n$, это тоже не удастся: если B и C отличаются от A в 99% мест, то B совпадает с C по крайней мере в 98% мест.

Аналогичное утверждение, хотя и не по столь очевидным причинам, справедливо для любой доли $\beta > 1/2$.

Лемма. Пусть $\beta > 1/2$. Количество точек в \mathbb{B}^n , попарные расстояния между которыми не меньше βn , не превосходит

$$\frac{1}{2\beta - 1} + 1.$$

Здесь важно, что оценка на число точек не зависит от n (хотя и зависит от β : чем ближе β к $1/2$, тем слабее оценка).

Доказательство леммы. Удобно вместо последовательностей нулей и единиц рассматривать последовательности единиц и минус единиц, считая их векторами в \mathbb{R}^n . Определим скалярное произведение в \mathbb{R}^n , положив

$$(\langle x_1, \dots, x_n \rangle, \langle y_1, \dots, y_n \rangle) = \frac{\sum x_i y_i}{n}.$$

Разница с обычным скалярным произведением в \mathbb{R}^n состоит лишь в дополнительном делении на n . Это технически удобно, поскольку при этом евклидова длина любого слова (которое, напомним, мы считаем вектором из плюс-минус единиц) равна 1.

Если расстояние Хэмминга между двумя кодовыми словами больше βn , то их скалярное произведение отрицательно и меньше $1 - 2\beta$. Теперь легко получить оценку на число векторов: если имеется N единичных векторов e_1, \dots, e_N в евклидовом пространстве V и при этом скалярное произведение любых двух из них меньше $1 - 2\beta$, то

$$0 \leq (\langle e_1 + \dots + e_N \rangle, \langle e_1 + \dots + e_N \rangle) \leq N + N(N-1)(1 - 2\beta),$$

(имеется N квадратов и $N(N-1)$ попарных произведений различных векторов), откуда

$$N - 1 \leq \frac{1}{2\beta - 1},$$

что и требовалось в лемме.

Таким образом, если мы хотим, чтобы количество передаваемой информации росло с ростом n , на исправление более чем 25% ошибок надеяться не приходится. В частности, в правой половине рис. 1 никаких интересных кодов нет, хотя оценка Хэмминга их и не запрещает.

Если требовать, чтобы доля ошибок была бы хоть чуть-чуть больше 50%, то все углы между кодовыми словами будут тупыми и число точек не больше $n + 1$, как показывает следующее простое утверждение:

Если несколько векторов евклидова пространства образуют попарно тупые углы, то после удаления любого из векторов получается линейно независимая система.

В самом деле, предположим, что вектора x_0, \dots, x_k образуют попарно тупые углы. Покажем, что x_1, \dots, x_k линейно независимы. Пусть это не так и

$$\lambda_1 x_1 + \dots + \lambda_k x_k = 0$$

Вычертим все нулевые коэффициенты. Если оставшиеся коэффициенты имеют один знак, то умножим скалярно на x_0 и получим противоречие:

сумма нескольких отрицательных скалярных произведений с коэффициентами одного знака равна нулю.

Если оставшиеся коэффициенты имеют разные знаки, то разнесём их в разные части и получим равенство

$$\lambda_i x_i + \dots = \lambda_j x_j + \dots,$$

где все коэффициенты положительны. Если обе части равны нулю, то смотри выше. Если же нет, то скалярное произведение левой части на правую одновременно положительно (как скалярный квадрат вектора) и отрицательно (как сумма отрицательных скалярных произведений с положительными коэффициентами). Лемма доказана.

Если разрешить и прямые углы (наряду с тупыми) то максимальное число векторов в n -мерном евклидовом пространстве возрастёт до $2n$. В самом деле, можно взять плюс-минус вектора базиса, их как раз $2n$. Больше векторов взять не удастся:

Если векторы в n -мерном евклидовом пространстве образуют попарно прямые или тупые углы, то их число не превосходит $2n$.

В самом деле, можно считать, что линейная оболочка векторов совпадает со всем пространством (иначе можно свести дело к меньшей размерности, рассуждая по индукции) и векторы x_1, \dots, x_n образуют базис. Выразим остальные x_k (при $k > n$) через x_1, \dots, x_n .

Шаг 1. Заметим, что в таких выражениях все ненулевые коэффициенты (а в каждом из выражений они есть, поскольку $x_k \neq 0$) отрицательны. В самом деле, предположим, что это не так и в каком-то из выражений

$$x_k = \lambda_1 x_1 + \dots + \lambda_n x_n.$$

есть положительные λ_i . Перенесём все отрицательные коэффициенты в левую часть, получим равенство

$$x_k + (-\lambda_s)x_s + \dots = \lambda_t x_t + \dots,$$

где все коэффициенты при x_i положительны и в правой части что-то осталось (ведь были положительные коэффициенты). Тогда правая часть этого равенства (а значит, и левая) отлична от нуля в силу линейной независимости векторов базиса. Произведение левой части на правую должно быть одновременно положительно (как скалярный квадрат ненулевого вектора) и неположительно (поскольку после раскрытия скобок становится суммой неположительных скалярных произведений с положительными коэффициентами). Противоречие.

Шаг 2. Если общее число векторов больше $2n$, то вектора x_k при $k > n$ (их не меньше $n + 1$ штук в n -мерном пространстве) линейно зависимы. Коэффициенты их нулевой линейной комбинации не могут быть одного знака, ведь в выражениях через базисные вектора x_1, \dots, x_n коэффициенты отрицательны и сократиться друг с другом не могут. Значит, есть разные знаки и можно снова разнести их по разным частям:

$$\mu_s x_s + \dots = \mu_t x_t + \dots,$$

где все коэффициенты μ_i положительны. Обе части содержат хотя бы один ненулевой член и потому не равны нулю (как мы уже знаем про линейные комбинации с коэффициентами одного знака). Поэтому скалярное произведение левой части и правой одновременно положительно (как скалярный квадрат ненулевого вектора) и неположительно (как сумма неположительных скалярных произведений с положительными коэффициентами). Противоречие.

Таким образом, мы приходим к оценке Плоткина: число кодовых слов длины n с попарными расстояниями не меньше $n/2$ не превосходит $2n$.

14 Улучшение оценки Синглетона

Имея оценку Плоткина, вернёмся к рассуждению, использованному для доказательства оценки Синглетона, и получим более сильную оценку. Будем рассматривать случай кодов в двухбуквенном алфавите.

Пусть код имеет длину кодовых слов n , длину кодируемого слова k и расстояние d (как говорят, $[n, k, d]_2$ -код; индекс 2 — размер алфавита). Принцип Дирихле показывает, что для любого t от 1 до $k - 1$ среди 2^k кодовых слов можно указать 2^{k-t} кодовых слов, которые совпадают в первых t битах. Они образуют код с параметрами $[n - t, k - t, d]_2$ (поскольку первые t битов совпадают, d различий приходится на остальные $n - t$ битов).

Доказывая оценку Синглетона, мы брали $t = k - 1$ и замечали, что для полученного кода (в котором не менее двух кодовых слов) расстояние не больше длины кодового слова:

$$n - (k - 1) \geq d$$

Теперь мы можем взять меньшее t , при котором у полученного кода длина кодового слова будет равна удвоенному расстоянию:

$$n - t = 2d, \quad \text{или} \quad t = n - 2d.$$

Согласно оценке Плоткина, число кодовых слов не превосходит удвоенной длины:

$$2^{k-t} \leq 4d, \quad \text{или} \quad k - n + 2d \leq \log 4d.$$

Замечая, что $d \leq n$ и деля на n получаем оценку

$$\frac{k}{n} + 2\frac{d}{n} \leq 1 + 4 \log n/n.$$

При больших n последним слагаемым можно пренебречь и на рис. 1 появляется новая граница (пунктир на рис. 2).

Видно, что она кое-где сильнее, а кое-где слабее границы Хэмминга.

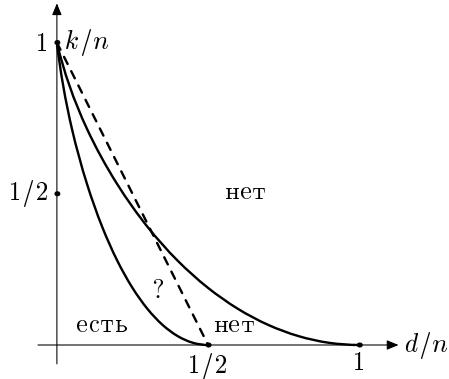


Figure 2: Улучшение границы Синглетона.

15 Код Адамара

Оказывается, что оценка Плоткина является точной, если n есть степень двойки. Соответствующий пример доставляют коды Адамара.

Код Адамара состоит из $2n$ кодовых слов длины n , любые два из которых отличаются либо ровно в половине позиций (так что соответствующие векторы ортогональны), либо во всех позициях. Код Адамара строится при $n = 2^s$. Для этого позиции в слове будем представлять себе как вершины s -мерного булева куба \mathbb{B}^s , а слова — как функции $\mathbb{B}^s \rightarrow \mathbb{B}$. Такая функция задаётся своими значениями в $2^s = n$ вершинах, и эти значения образуют слово длины n , надо только фиксировать какой-либо порядок на вершинах куба.

В качестве кодовых слов возьмём аффинные функции, то есть функции вида

$$\langle x_1, \dots, x_s \rangle \mapsto a_0 + a_1 x_1 + \dots + a_s x_s$$

при $a_0, \dots, a_s \in \mathbb{B}$ (умножение и сложение — как в поле из двух элементов). Такая функция задаётся набором своих коэффициентов, и потому имеется $2^{s+1} = 2n$ аффинных функций.

Две такие функции либо различаются во всех точках (если отличаются лишь коэффициентом a_0), либо ровно в половине точек (образующих аффинное подпространство коразмерности 1 над полем \mathbb{B}). Код Адамара построен.

С точки зрения структуры евклидова пространства \mathbb{R}^n , рассмотренного в предыдущем разделе, кодовые слова кода Адамара являются плюс-минус базисными векторами ортонормированного базиса (замена знака соответствует добавлению единицы к аффинной функции, то есть изменению a_0).

Итак, к настоящему времени у нас есть три явные конструкции кодов для двухбуквенного алфавита: код Хэмминга, код Форни – Юстесена – Воненкрафта и код Адамара. Код Хэмминга имеет коэффициент полезного

действия, близкий к 100%, но исправляет только одну ошибку. Напротив, код Адамара исправляет почти что максимально возможное число ошибок (до 25%), но зато имеет очень малый коэффициент полезного действия. Код Форни занимает промежуточное положение: у него и доля исправляемых ошибок, и коэффициент полезного действия отделены от нуля, хотя и невелики.

Для больших алфавитов ситуация лучше: там код Рида – Соломона при подходящем выборе параметров позволяет достичь любого заданного коэффициента полезного действия и исправляет при этом максимально возможное (по неравенству Синглетона) число ошибок.

Замечание. Если мы хотим явно указать код, приближающийся к границе Плоткина (50%), то можно использовать каскадный код, в котором внутренним кодом является код Адамара, а внешним — код Рида – Соломона.

Рассмотрим код Адамара с 2^{m+1} кодовыми словами размера 2^m . Используя его как внутренний код, мы получаем для внешнего кода алфавит из 2^{m+1} символов. Для простоты записи формул пожертвуем половиной и будем использовать лишь 2^m из них. Зафиксируем некоторое $\varepsilon > 0$. Внешний код Рида – Соломона будет кодировать $\varepsilon 2^m$ таких символов (блоков из m битов) с помощью 2^m символов (блоков), каждый из которых при внутреннем кодировании изображается 2^m битами.

В итоге параметры каскадного кода таковы: длина входного слова $\varepsilon m 2^m$; длина выходного слова $(2^m)^2$; кодовое расстояние (в расчёте на символ) не меньше произведения кодовых расстояний, то есть $\frac{1}{2}(1 - \varepsilon)$.

Таким образом, мы можем достичь кодового расстояния, сколь угодно близкого к 50% (при малом фиксированном ε). При этом длина кодового слова ограничивается примерно квадратом длины кодируемого слова.

(Такая граница представляет интерес лишь потому, что наш код описан явно — граница Варгамова–Гилберта позволяет получить линейные коды с лучшими параметрами, которые можно использовать либо сами по себе, либо как внутренний код для кода Рида – Соломона, как в конструкции Форни.)

16 Вероятностное декодирование кодов Адамара

Пусть фиксировано некоторое значение $\alpha < 1/4$. Тогда, как мы знаем, возможно однозначное декодирование кода Адамара с исправлением до α ошибок (на символ).

Можно ли это делать за полиномиальное время? Постановка этого вопроса требует уточнения: полиномиальное время от чего? От длины кодируемого слова или длины кодового слова? Поскольку мы кодируем $m + 1$ битов с помощью 2^m битов, разница весьма существенна.

Тривиальный ответ таков: за полиномиальное от 2^m время мы можем

перебрать все 2^{m+1} возможных кодируемых слов и найти нужное, а за полиномиальное от m время мы сможем прочесть лишь пренебрежимо малую часть кодового слова, и вся эта часть может попасть в зону ошибок, так что декодирование невозможно.

(Более аккуратное рассуждение: проведём декодирование для какого-то одного случая, скажем, нулевого слова, потом посмотрим, какие позиции в кодовом слове мы прочли, и во всех кодовых словах эти позиции сделаем нулевыми; доля ошибок будет невелика, а декодирование разрушено.)

Другое возможное уточнение: говоря о декодировании слова длины 2^m за полиномиальное от m время, будем предполагать, что это слово задано нам “как оракул”: по номеру бита (этот номер имеет длину m) нам сообщают значение соответствующего бита. (Это уточнение необходимо, поскольку, скажем, давать на вход слово длины 2^m на ленте бессмысленно, поскольку будет доступно лишь его начало полиномиальной длины.)

Оказывается, что в данной постановке задачи декодирование за полиномиальное время может быть выполнено вероятностным алгоритмом со сколь угодно малой вероятностью ошибки. Точная формулировка:

Теорема. Для всякого $\alpha < 1/4$ и для всякого $\varepsilon > 0$ существует вероятностный алгоритм, который, получив число m и (в виде оракула) кодовое слово длины 2^m с не более чем $\alpha 2^m$ ошибок, работает полиномиальное от m время и правильно декодирует слово с вероятностью не менее $1 - \varepsilon$.

(Заметим, что полином, ограничивающий время работы, зависит от α и от ε : чем ближе α к $1/4$ и чем меньше ε , тем дольше работает алгоритм.)

Доказательство. По условию мы можем найти значение неизвестной аффинной функции $f: \mathbb{B}^n \rightarrow \mathbb{B}$, имеющей вид

$$f(x_1, \dots, x_n) = f_0 + f_1 x_1 + f_2 x_2 + \dots + f_n x_n$$

в случайной точке с вероятностью ошибки не больше α . Коэффициент f_1 можно записать как разность значений в двух точках, отличающихся по первой координате:

$$f_1 = f(x_1 + 1, x_2, \dots, x_n) - f(x_1, \dots, x_n).$$

Если в качестве (x_1, \dots, x_n) взять случайную равномерно распределённую точку, то сдвинутая точка $(x_1 + 1, \dots, x_n)$ также будет равномерно распределена (хотя, конечно, эти две точки не будут независимы). Каждое из двух значений f нам известно с вероятностью ошибки не больше 2α , поэтому правильное значение для f_1 будет получено с вероятностью не меньше $1 - 2\alpha > 50\%$.

Повторяя это несколько раз (для независимых точек) и затем определяя ответ большинством, можно (как известно из теории вероятности) быстро уменьшать вероятность ошибки и тем самым найти коэффициент f_1 со сколь угодно малой вероятностью ошибки. Аналогично найдём и все остальные f_i , после чего уже можно находить f_0 (тоже голосованием по нескольким точкам).

Теорема доказана.

Замечание. Как известно из теории вероятностей, при таком повторении (и голосовании) вероятность ошибки убывает быстро, поэтому можно сделать её, скажем, меньше 2^{-m} , оставив алгоритм полиномиальным по m .

17 Коды Рида – Маллера

Коды Рида – Соломона и коды Адамара являются двумя крайними случаями в семействе кодов, называемых *кодами Рида – Маллера*: в кодах Рида – Соломона мы рассматривали многочлены от одной переменной, но большой степени, а в кодах Адамара – от многих переменных, но первой степени.

В общем случае мы рассматриваем многочлены от k переменных степени не выше d над полем \mathbb{F}_q . При этом степень понимается как суммарная степень по всем переменным. (При $k = 1$ получаются коды Рида – Соломона, при $d = 1$ – коды Адамара.) Алфавит состоит из q символов (элементов поля); коэффициенты многочлена степени не выше d образуют кодируемое слово, а значения этого многочлена во всех точках \mathbb{F}^k – кодовое слово.

Длина кодового слова равна q^k , а длина кодируемого слова равна числу решений неравенства

$$m_1 + \dots + m_k \leq d$$

в неотрицательных целых числах, то есть C_{d+k}^k (решение такого неравенства задаётся разбиением ряда из d объектов на $k+1$ групп с помощью k перегородок; числа m_1, \dots, m_k – числа объектов между перегородками; объекты справа от последней перегородки не входят ни в одно m_i и составляют разницу между частями неравенства.)

Оценка кодового расстояния основана на следующем простом алгебраическом утверждении:

Лемма. Пусть \mathbb{F}_q – поле из q элементов, а $P(x_1, \dots, x_k)$ многочлен от k переменных над этим полем, причём его степень (суммарная по всем переменным) равна d . Тогда доля точек $(x_1, \dots, x_k) \in \mathbb{F}^k$, для которых

$$P(x_1, \dots, x_k) = 0,$$

не превосходит d/q .

Доказательство. Лемма очевидна, если многочлен содержит член степени d , в который входит только одна переменная. Тогда при любых значениях остальных переменных получается ненулевой многочлен степени d , имеющий не более d корней, так что на каждой прямой (когда все остальные переменные фиксированы) доля нулей не больше d/q , и остаётся их усреднить.

К этому случаю можно пытаться сводить произвольный многочлен линейной невырожденной заменой переменных (которая не меняет суммарную степень); это заведомо возможно сделать, если поле достаточно велико. Но проще доказать утверждение леммы индукцией по числу переменных. Для $k = 1$ утверждение леммы общеизвестно.

Для произвольного k рассуждаем так. Выделим какую-нибудь переменную, например, x_1 , и рассмотрим моном с максимальной степенью по x_1 . Пусть эта степень равна s ; очевидно, $s \leq d$. Запишем P как многочлен по x_1 , коэффициенты которого есть многочлены от x_2, \dots, x_k . Коэффициент при x_1^s представляет собой некоторый многочлен $Q(x_2, \dots, x_k)$ степени не больше $d - s$. Случай $d - s = 0$ мы уже обсуждали. В общем случае для равномерно распределённых случайных x_1, \dots, x_k вероятность события

$$Q(x_2, \dots, x_k) = 0$$

по предположению индукции не превосходит $(d - s)/q$, а вероятность события

$$P(x_1, \dots, x_k) = 0, \text{ но } Q(x_2, \dots, x_k) \neq 0$$

не превосходит s/q , поскольку при каждом x_2, \dots, x_k , при которых $Q(x_2, \dots, x_k) \neq 0$, существует не более s значений x_1 , при которых $P(x_1, \dots, x_k) = 0$. (Так что даже и условная вероятность

$$P(x_1, \dots, x_k) = 0 \text{ при условии } Q(x_2, \dots, x_k) \neq 0$$

не превосходит s/q). Складывая вероятности, получаем искомую оценку d/q . Лемма доказана.

Таким образом, кодовое расстояние не меньше $q^k(1 - d/q)$, то есть $(1 - d/q)$ в расчёте на один символ. Например, при $d = 1$ и $q = 2$ получается расстояние 50%, как мы уже видели для кодов Адамара.

Для примера рассмотрим случай $k = 2$. Кодовое слово состоит из q^2 символов, а кодируемое слово из $C_{d+2}^2 = (d+1)(d+2)/2 \approx d^2/2$ символов. Таким образом, коэффициент полезного действия кода примерно равен $(1/2)d^2/q^2$, что значительно хуже, чем у кодов Рида – Соломона при том же удельном кодовом расстоянии $1 - d/q$. Зато размер алфавита теперь уже равен корню из длины кодового слова (а не самой этой длине).

18 Коды БЧХ

Эти коды названы БЧХ (в английском варианте — BCH) по именам своих изобретателей: Боуза (R.C. Bose), Чоудхури (D.K. Ray-Chaudhuri) и Хоквингема (A. Hocquenghem). Они позволяют исправлять любое фиксированное число ошибок над двухбуквенным алфавитом и примыкают к коду Хэмминга (который является их частным случаем).

Рассмотрим поле \mathbb{F} из $n = 2^k$ элементов и многочлены степени меньше n с коэффициентами в этом поле. Такой многочлен

$$A(x) = a_0 + a_1 x + \dots + a_{n-1} x^{n-1}$$

определяется n коэффициентами a_0, \dots, a_{n-1} . С другой стороны, он однозначно определяется своими значениями в n точках поля \mathbb{F} , которые можно выбрать произвольно, так что соответствие

$$\text{коэффициенты} \leftrightarrow \text{значения}$$

является изоморфизмом n -мерных пространств над полем \mathbb{F} . (Этот изоморфизм является дискретным вариантом преобразования Фурье.)

Наложим теперь на многочлен A некоторые ограничения. Во-первых, потребуем, чтобы его степень была меньше $n - s$ (для некоторого фиксированного s). Другими словами, потребуем, чтобы старшие s коэффициентов равнялись нулю. (Таблицы значений таких многочленов образуют, как мы помним, код Рида – Соломона с расстоянием $s + 1$.)

Во-вторых, потребуем ещё, чтобы значения многочлена A во всех точках поля равнялись нулю или единице (поля \mathbb{F}). В этом случае таблица значений будет двоичным словом длины n .

Все такие таблицы и являются кодовыми словами кода БЧХ.

Переформулировка: слово из n нулей и единиц является кодовым словом кода БЧХ, если соответствующий ему многочлен (принимающий указанные значения в n точках поля \mathbb{F}) имеет степень меньше $n - s$. (Здесь n и s — параметры кода.)

Кодовое расстояние этого кода не меньше $s + 1$ (поскольку он является частью кода Рида – Соломона с таким кодовым расстоянием). Сложнее понять, сколько при этом образуется кодовых слов. Хотя оба ограничения на многочлен A просты, но одно из них формулируется в терминах его коэффициентов, а другое — в терминах значений, и не так просто понять, как они взаимодействуют друг с другом.

Для этого нам понадобятся некоторые сведения из алгебры. В поле \mathbb{F} выделим подполе $\mathbb{F}_2 \subset \mathbb{F}$, состоящее из нуля и единицы. [Чтобы убедиться, что это действительно подполе, достаточно проверить, что $1 + 1 = 0$ в \mathbb{F} , то есть что характеристика поля \mathbb{F} равна 2. Это доказывается так: если характеристика равна $p > 2$, то в \mathbb{F} есть подполе из p элементов, и \mathbb{F} есть векторное пространство над этим подполем, так что размер \mathbb{F} есть степень числа p .]

Как мы уже говорили, многочлены степени меньше n образуют векторное пространство над \mathbb{F} ; условие обращения s старших коэффициентов в нуль задаёт подпространство этого пространства. Но второе наше условие — что значения во всех точках нули и единицы — не является линейным над \mathbb{F} . Однако оно является линейным над \mathbb{F}_2 (по тривиальным причинам). Поэтому построенное нами множество кодовых слов кода БЧХ (обозначим его C) является векторным пространством над полем \mathbb{F}_2 , и надо только определить его \mathbb{F}_2 -размерность.

Если бы не требование обращения в нуль s старших коэффициентов, то \mathbb{F}_2 -размерность C была бы равна n . Обращение в нуль каждого из s коэффициентов задаётся k уравнениями: коэффициент принадлежит полю \mathbb{F} , которое имеет размерность k над \mathbb{F}_2 .

Следствие: \mathbb{F}_2 -размерность C не меньше $n - sk$, то есть $n - s \log n$.

Это уже кое-что: мы получаем код длины n с $s \log n$ проверочными символами (и $n - s \log n$ значащими) и расстоянием $s + 1$. Например, при $s = 2$ получается код с расстоянием 3 (как и у кода Хэмминга) и $2 \log n$ проверочными символами (что вдвое больше, чем у Хэмминга).

Однако на самом деле ситуация оказывается ещё немного лучше: ks

условий, соответствующих обращению в нуль старших s коэффициентов многочлена A , линейно зависимы над полем \mathbb{F}_2 . Чтобы понять это, нам понадобится вспомнить ещё кое-что из алгебры.

Для начала заметим, что условие “все значения многочлена A — нули или единицы” можно переформулировать так: $A^2(x) = A(x)$ для всех $x \in \mathbb{F}$. Другими словами, многочлен $A^2 - A$ должен обращаться в нуль во всех точках поля \mathbb{F} . Это не значит, что все его коэффициенты нулевые (ведь степень многочлена $A^2 - A$ может быть почти в два раза больше числа элементов в поле), а означает лишь, что A делится на многочлен

$$P(x) = \prod_{\alpha \in \mathbb{F}} (x - \alpha)$$

Последний многочлен равен $x^n - x$. Действительно, по теореме Лагранжа порядок каждого элемента в мультиликативной группе поля делит порядок группы, равный $n - 1$ (на самом деле верно более сильное свойство: мультиликативная группа поля обязана быть циклической; но это сейчас не важно). Поэтому $x^{n-1} = 1$ для любого ненулевого элемента поля, и $x^n = x$ для любого элемента поля. Значит, многочлен $x^n - x$ обращается в нуль во всех точках поля, поэтому он делится на P ; остается заметить, что у этих двух многочленов совпадают степени и старшие коэффициенты.

Итак, условие “все значения A — нули или единицы” можно переформулировать так: $A^2 - A$ делится на многочлен $x^n - x$ без остатка. Как записать это условие в терминах коэффициентов многочлена A ?

Заметим, что делить с остатком на $x^n - x$ очень просто. Надо понизить степени по правилам

$$\begin{aligned} x^n &\rightarrow x \\ x^{n+1} &\rightarrow x^2 \\ x^{n+2} &\rightarrow x^3 \\ &\dots \\ x^{2n-2} &\rightarrow x^{n-1} \end{aligned}$$

(Дальше должна идти строка $x^{2n-1} \rightarrow x^n \rightarrow x$, но до таких степеней в нашем случае дело не дойдёт.) Затем надо привести подобные члены. (Эта процедура соответствует обычному делению многочленов “уголком”.)

Сделаем это для многочлена $A^2 - A$, если

$$A(x) = a_{n-1}x^{n-1} + a_{n-2}x^{n-2} + \dots + a_1x + a_0.$$

Вычислить A^2 легко, если вспомнить, что в поле характеристики 2, где $1 + 1 = 0$, имеет место равенство $(u + v)^2 = u^2 + v^2$, поскольку член с $2uv$ обращается в нуль. Поэтому квадрат суммы есть сумма квадратов, и

$$A^2(x) = a_{n-1}x^{2n-2} + a_{n-2}x^{2n-4} + \dots + a_1x^2 + a_0.$$

Делимость $A^2 - A$ на $x^n - x$ означает, что после замен одночленов в соответствии с приведённой выше таблицей из A^2 должно получиться A , то есть

$$\begin{aligned} a_{n-1}^2 &= a_{n-1} \\ a_{n-2}^2 &= a_{n-3} \\ a_{n-3}^2 &= a_{n-5} \\ &\dots \\ a_{n/2}^2 &= a_1 \end{aligned}$$

(последнюю строку можно получить, заметив, что n чётно и что индекс в левой части есть полусумма $n - 1$ и индекса в правой части). Заметим, что несмотря на свой квадратичный вид, каждое из этих условий является \mathbb{F}_2 -линейным (поскольку возведение в квадрат, как мы уже говорили, линейно над полем характеристики 2).

Итак, мы записали условие “все значения многочлена A — нули или единицы” в виде \mathbb{F}_2 -линейных уравнений на его коэффициенты. Как мы знаем, пространство решений этой системы линейных уравнений имеет размерность n . А хотим мы выяснить, напомним, насколько уменьшится размерность, если наложить дополнительные ограничения $a_{n-1} = 0, \dots, a_{n-s} = 0$.

Про a_{n-1} мы и так уже знаем, что $a_{n-1}^2 = a_{n-1}$, то есть что a_{n-1} равно нулю или единице. Поэтому условие $a_{n-1} = 0$ уменьшает размерность пространства решений на 1 (а не на k , как было в нашей прежней оценке). Дальнейшие уравнения системы выражают $a_{n-3}, a_{n-5}, \dots, a_1$ через a_i с большими индексами. Поэтому условия обращения в нуль достаточно записывать лишь для a_{n-2}, a_{n-4}, \dots вплоть до a_{n-s} (для чётного s) и a_{n-s+1} (для нечётного s).

Ограничимся для простоты случаем чётного s (при этом кодовое расстояние будет не меньше $s + 1$, и можно исправлять $s/2$ ошибок). Тогда получится $s/2$ условий коразмерности k плюс ещё одно условие коразмерности 1 (на a_{n-1}). Отсюда получаем, что \mathbb{F}_2 -размерность пространства кодов БЧХ длины n с расстоянием не меньше $s + 1$ для чётного s равна $n - 1 - ks/2 = n - 1 - (s/2) \log n$.

Словами: на каждую исправляемую ошибку нужно $\log n$ контрольных битов, плюс ещё один контрольный бит на всех.

Интересно сравнить параметры БЧХ-кодов с границей Хэмминга. Шар радиуса $e = s/2$ содержит примерно $C_n^e \approx n^e/e!$ элементов (мы считаем, что $e \ll n$ и потому заменяем $n(n-1)\dots(n-e+1)$ на n^e). Граница Хэмминга говорит, что логарифм числа кодовых слов не превосходит примерно

$$n - \log(n^e/e!) = n - e \log n + \log e!;$$

первые два слагаемых как раз соответствуют БЧХ-кодам, так что разница лишь на $\log e!$.

19 БЧХ и Хэмминг

Покажем, что код Хэмминга может быть получен как частный случай кода БЧХ.

Пусть, например, $k = 3$, $n = 8$ и мы рассматриваем поле \mathbb{F}_8 . Многочлен A однозначно определяется своими значениями в 8 точках этого поля, а также 8 коэффициентами a_7, a_6, \dots, a_0 . Условие “ A принимает лишь значения 0 и 1” запишется как система уравнений

$$a_7^2 = a_7, \quad a_6^2 = a_5, \quad a_5^2 = a_3, \quad a_4^2 = a_1.$$

Наложив ограничение $a_7 = 0$, мы получим код размерности 7 (одно уравнение на 8 переменных) с расстоянием 2. Легко понять, что это за код: поскольку расстояние равно 2, то в уравнение обязаны входить все переменные, и это уравнение есть проверка на чётность (сумма по модулю 2 равна нулю).

Следующее ограничение $a_6 = 0$. Оно соответствует трём уравнениям и уменьшает размерность кода до 4. Из уравнения $a_6^2 = a_5$ видно, что в этом случае $a_5 = 0$, так что кодовое расстояние будет не меньше 4. Выбросив любой бит, мы не изменим размерность кода (поскольку по условию чётности он определялся остальными) и уменьшим расстояние не более чем на 1. Получится код длины 7 и размерности 4 с кодовым расстоянием не меньше 3 — всё как у кода Хэмминга.

Чтобы убедиться, что это и есть код Хэмминга, надо выяснить, как от значений многочлена A в точках поля перейти к его коэффициентам. Это делается по интерполяционной формуле Лагранжа:

$$A(x) = \sum_{\alpha \in \mathbb{F}} A(\alpha) P_\alpha(x),$$

где P_α — многочлен (степени меньше n), равный 1 в точке α и 0 в остальных точках поля. В данном случае в качестве такого многочлена можно взять

$$P_\alpha(x) = (x - \alpha)^{n-1} + 1.$$

В самом деле, при $x \neq \alpha$ первое слагаемое равно 1 (порядок мультипликативной группы поля, равный $n-1$, делится на порядок любого её элемента), и многочлен обращается в нуль (наше поле характеристики 2).

Разложение $(x - \alpha)^{n-1}$ по биному Ньютона даёт (в поле характеристики 2) многочлен

$$x^{n-1} + x^{n-2}\alpha + x^{n-3}\alpha^2 + \dots + x\alpha^{n-2} + \alpha^{n-1}.$$

В этом можно убедиться, вспомнив, что в строке треугольника Паскаля, номер которой на единицу меньше степени двойки, все члены нечётные. А можно домножить записанную сумму на $(x - \alpha)$, получится $x^n - \alpha^n$, что равно $(x - \alpha)^n$ (поскольку возведение в квадрат, а также в любую степень двойки, перестановочно со сложением).

Так или иначе, мы можем теперь записать более конкретно условия обращения в нуль коэффициентов a_7 и a_6 в терминах значений многочлена A . Как видно из формулы Лагранжа и формулы для P_α ,

$$a_7 = \sum_{\alpha \in \mathbb{F}} A(\alpha), \quad a_6 = \sum_{\alpha \in \mathbb{F}} \alpha A(\alpha).$$

Поэтому условие на a_7 представляет собой проверку на чётность (это мы и так знаем из общих соображений). Условие на a_6 представляет собой равенство

$$\sum_{\alpha} \alpha A(\alpha) = 0$$

в поле \mathbb{F} , которое можно рассматривать как векторное пространство размёрности 3 над \mathbb{F}_2 . При этом семь ненулевых элементов α превращаются в семь ненулевых векторов из \mathbb{F}_2^3 , то есть в векторы

$$(0, 0, 1), (0, 1, 0), (0, 1, 1), (1, 0, 0), (1, 0, 1), (1, 1, 0), (1, 1, 1),$$

и условия на коэффициенты $A(\alpha)$ при $\alpha \neq 0$ будут те самые, что были в коде Хэмминга. Поэтому из кода БЧХ получается код Хэмминга, если отбросить $A(0)$, как мы и говорили.

В этом примере мы считали, что $k = 3$ ($n = 8$), но всё сказанное очевидно переносится и на случай произвольного k .

20 Декодирование списком

До сих пор мы требовали, чтобы исправление ошибок происходило однозначно. Посмотрим, что будет, если ослабить это требование и разрешить до L вариантов декодирования (при некотором L). Более формально, множество кодовых слов должно быть таким, чтобы любой шар радиуса e содержал не более L кодовых слов. В этом случае мы говорим, что код *допускает декодирование списком длины L* (с исправлением e ошибок).

Как и раньше, нас интересует возможность построения такого множества при заданных параметрах q (размер алфавита), k (длина кодируемого слова), n (длина кодовых слов), e (число возможных ошибок) и, наконец, L . (Случай $L = 1$ соответствует прежней постановке задачи.)

Аналог границы Хэмминга теперь выглядит так:

$$q^k V_q(e, n) \leq L q^n$$

В самом деле, шары радиуса e в количестве q^k штук содержат по $V_q(e, n)$ элементов каждый и покрывают множество из q^n элементов не более чем в L слоёв.

В логарифмической шкале:

$$\frac{k}{n} + \frac{\log_q V_q(e, n)}{n} \leq 1 + \frac{\log_q L}{n}$$

Таким образом, если рассматривать не слишком большие L (скажем, полиномиальные от n), то граница почти не сдвигается.

Зато сдвигается другая граница: указанное только что необходимое условие существование кода оказывается почти что достаточным. А именно, верно такое утверждение:

Теорема. Пусть выполнено неравенство Хэмминга (в прежней форме, для $L = 1$):

$$q^k V_q(e, n) \leq q^n$$

Тогда существует код, допускающий декодирование списком длины L , где $L = O(n \log q)$.

Точнее говоря, нам годится любое L , при котором $L! > q^n$; поскольку $L! \approx (L/2,718\dots)^L$, это даёт оценку $L = O(n \log q)$.

Доказательство. Покажем, что случайно выбранный код допускает декодирование L -списком с положительной вероятностью (или, другими словами, что число кодов, не допускающих такого декодирования, меньше общего числа кодов).

Всего кодов (точнее, отображений $\Sigma^k \rightarrow \Sigma^n$) имеется $(q^n)^{(q^k)}$. Подсчитаем число плохих — тех, где некоторое слово покрывается L (или более) шарами. Плохое отображение можно задать, указав

- плохое слово (покрытое L или более шарами) [q^n вариантов];
- индексы покрывающих шаров [подмножество размера L в множестве Σ^k , всего $C_{q^k}^L$ вариантов];
- центры покрывающих шаров (=кодовые слова, попадающие в шар радиуса e с центром в точке, выбранной на первом шаге) [L точек в шаре, всего $V_q(e, n)^L$ вариантов];
- остальные кодовые слова [$q^k - L$ точек, всего $(q^n)^{q^k-L}$ вариантов].

Таким образом, общее число плохих отображений не превосходит

$$\begin{aligned} q^n C_{q^k}^L (V_q(e, n))^L (q^n)^{q^k-L} &\leq \\ &\leq q^n \frac{(q^k)^L}{L!} (V_q(e, n))^L (q^n)^{q^k-L} \end{aligned}$$

(на последнем шаге мы использовали оценку $C_v^u \leq (v^u)/u!$, которая получается из формулы для числа сочетаний, если все множители в числителе заменить на наибольший). Таким образом, всё будет хорошо, если

$$q^n \frac{(q^k)^L}{L!} (V_q(e, n))^L (q^n)^{q^k-L} < (q^n)^{q^k},$$

что после сокращений даёт

$$\frac{1}{L!} (q^k V_q(e, n))^L < (q^n)^{L-1}.$$

По предположению теоремы $q^k V_q(e, n) \leq q^n$ (граница Хэмминга), поэтому достаточно неравенства $q^n < L!$, как мы и говорили. Теорема доказана.

Замечание. Если немного уменьшить пропускную способность конструируемого кода, предположив, что

$$\frac{k}{n} + \frac{\log_q V_q(e, n)}{n} \leq c < 1$$

то в левой части наших оценок появится дополнительный множитель $((q^{c-1})^n)^L$, меньший единицы, поскольку тогда

$$q^k V_q(e, n) \leq q^{cn} = q^n (q^{c-1})^n,$$

и останется неравенство

$$q^n ((q^{c-1})^n)^L < L!,$$

которое выполняется при $L = O(1)$ (величина L зависит от выбора c и q , но не растёт с ростом n). В самом деле, достаточно взять L , при котором

$$q \cdot (q^{c-1})^L \leq 1.$$

Мы доказали существование кодов, декодируемых списком, вблизи границы Хэмминга, но не указали явно этих кодов. Сложность описания построенных кодов экспоненциальна, не говоря уже о времени кодирования и декодирования.

21 Кодовое расстояние и декодирование списком

Пусть имеется код $F: \Sigma^k \rightarrow \Sigma^n$ с минимальным расстоянием d между кодовыми словами. Мы уже знаем, что он позволяет декодировать e ошибок при $e < d/2$. Переходя от различающихся позиций к совпадающим, можно переформулировать это так. Пусть известно, что любые два кодовых слова совпадают максимум в u ($=n-d$) позициях. Тогда для любого слова $y \in \Sigma^n$ не более одного кодового слова может совпасть с y более чем в $(n+u)/2$ ($=n-d/2$) позициях.

В этих же обозначениях удобно формулировать утверждение о декодировании списком, заменив среднее арифметическое на среднее геометрическое:

Теорема. Пусть любые два кодовых слова (из Σ^n) совпадают максимум в u позициях. Тогда для любого слова $y \in \Sigma^n$ не более чем $(n+1)$ слов могут совпадать с ним более чем \sqrt{nu} позициях.

(Заметим, что среднее геометрическое больше среднего арифметического, так что всё согласовано.)

Доказательство. Пусть слова y_1, \dots, y_N совпадают со словом y более чем в \sqrt{nu} позициях (каждое в своих). Пусть $Y_i \subset \{1, 2, \dots, n\}$ — номера позиций, где y_i совпадает с y . Тогда каждое из множеств Y_i содержит

более \sqrt{nu} элементов, а пересечение $Y_i \cap Y_j$ при $i \neq j$ содержит не более u элементов.

Рассмотрим характеристические функции множеств Y_i как случайные величины на вероятностном пространстве $\{1, \dots, n\}$ (с равномерным распределением). Напомним, что корреляция двух случайных величин ξ и η определяется как

$$\langle \xi, \eta \rangle = E[(\xi - E\xi)(\eta - E\eta)],$$

где E — математическое ожидание (в данном случае — среднее арифметическое n чисел). Другими словами, корреляция ξ и η есть скалярное произведение $\xi - E\xi$ и $\eta - E\eta$.

Раскрывая скобки и пользуясь линейностью математического ожидания, получаем, что

$$\langle \xi, \eta \rangle = E(\xi\eta) - (E\xi)(E\eta).$$

Для случая, когда случайные величины — индикаторы событий (равны единице, если событие произошло, и нулю, если не произошло), получаем формулу

$$\langle \xi_A, \xi_B \rangle = \Pr[A \text{ и } B] - \Pr[A]\Pr[B];$$

корреляция равна нулю, когда события независимы.

В данном случае вероятность каждого события больше $\sqrt{nu}/n = \sqrt{u/n}$, а вероятность пересечения любых двух не больше u/n , так что корреляции отрицательны.

Теперь вспомним, что корреляции можно записать как скалярные произведения. А мы уже видели, что в n -мерном пространстве может быть не более $(n+1)$ векторов, образующих друг с другом тупые углы.

Теорема доказана.

Заметим, что если разрешить каждому Y_i содержать ровно \sqrt{nu} элементов, то углы из тупых станут неострыми, и вместо $n+1$ получится $2n$ векторов.

Возвращаясь к исходным параметрам: если минимальное расстояние кода $F: \Sigma^k \rightarrow \Sigma^n$ равно d , то код допускает декодирование $(n+1)$ -списком с исправлением менее чем $n - \sqrt{n(n-d)}$ ошибок.

Доказанную теорему можно прочесть и так: при $n - e > \sqrt{n(n-d)}$ в шаре радиуса e может содержаться не более чем $n+1$ элементов с попарными расстояниями d или более. (Имеется в виду расстояние Хэмминга в Σ^n .)

Для кода с кодовым расстоянием 50% (в частности, для кода Адамара) эта теорема устанавливает возможность декодирования списком при доле ошибок $1 - \sqrt{1/2} \approx 29\%$, что лишь немногим больше границы в 25% для однозначного декодирования. Однако (в отличие от случая однозначного декодирования) даваемая этой теоремой оценка отнюдь не является точной. Например, для кодов Адамара возможно декодирование списком при любой фиксированной доле ошибок, меньшей $1/2$. (Более точную оценку Джонсона мы приведём дальше.)

22 Декодирование списком кодов Адамара

Пусть $\varepsilon > 0$ — произвольное положительное число.

Теорема. Число кодовых слов кода Адамара, для которых доля несопадений с данным словом не больше $\frac{1}{2}(1 - \varepsilon)$, не превосходит $1/\varepsilon^2$.

Доказательство. Вспомним, что кодовые слова кода Адамара были плюс-минус базисными векторами ортонормированного базиса в евклидовом пространстве, если рассматривать кодовые слова как последовательности единиц и минус единиц и определять скалярное произведение по формуле

$$\langle (x_1, \dots, x_n), (y_1, \dots, y_n) \rangle = \frac{1}{n} \sum_i x_i y_i$$

(при этом n есть степень двойки, но сейчас это не важно).

Пусть x — произвольное слово (рассматриваемое как последовательность единиц и минус единиц). Если слово y отличается от него не более чем в $\frac{1}{2}(1 - \varepsilon)n$ позициях, то

$$\langle x, y \rangle > \varepsilon$$

Теперь надо в качестве y взять все базисные векторы (с плюсом и минусом), и оценить, для скольких из них такое возможно. Из пары векторов y и $-y$ лишь один может удовлетворять этому неравенству; заменяя знаки у базисных векторов, можно считать, что это вектор с плюсом.

По теореме Пифагора (которую в данном случае называют равенством Парсеваля) квадрат гипотенузы $\langle x, x \rangle$ равен сумме квадратов сторон $\langle x, y_i \rangle$, взятой по всем базисным векторам y_i . В нашем случае $\langle x, x \rangle = 1$, поэтому количество y_i , при которых $\langle x, y_i \rangle \geq \varepsilon$, не превосходит $1/\varepsilon^2$, что и требовалось доказать.

23 Оценка Джонсона

Аналогичное утверждение можно доказать для любых кодов (над двухбуквенным алфавитом) с расстоянием около 50%. Вот точная формулировка:

Теорема. Пусть код имеет длину кодовых слов n и расстояние не меньше $\frac{1}{2}(1 - \varepsilon)n$ для некоторого $\varepsilon > 0$. Тогда он допускает декодирование списком при доле ошибок $\frac{1}{2}(1 - \sqrt{\varepsilon})$ и размере списка $2n$.

Мы сформулировали это утверждение в терминах кодов, но по существу речь идёт о точках в шаре: теорема утверждает, что в \mathbb{B}^n шар радиуса $\frac{1}{2}(1 - \sqrt{\varepsilon})n$ может содержать не более $2n$ точек с попарными расстояниями не меньше $\frac{1}{2}(1 - \varepsilon)n$.

Доказательство. Как и в доказательстве оценки Плоткина, будем рассматривать последовательности единиц и минус единиц, являющиеся векторами единичной длины в евклидовом пространстве \mathbb{R}^n .

Пусть шар с центром u имеет радиус $\frac{1}{2}(1 - \sqrt{\varepsilon})$ (в метрике Хэмминга) и содержит точки v_1, \dots, v_N , причём расстояние (ХэммингМаа) между v_i и v_j

не меньше $\frac{1}{2}(1 - \varepsilon)n$ при любых $i \neq j$. В терминах скалярного произведения это означает, что

$$(u, v_i) \geq \sqrt{\varepsilon} \quad \text{и} \quad (v_i, v_j) \leq \varepsilon.$$

Другими словами, угол между u и v_i острый и не слишком близок к прямому, в то время как угол между v_i и v_j достаточно близок к прямому или даже тупой.

Мы хотим доказать, что $N \leq 2n$. Это было бы так, если бы углы между v_i и v_j были тупыми или прямыми (см. доказательство оценки Плоткина). Чтобы свести дело к этому случаю, вычтем немного u из каждого v_i . Для этого найдём λ , при котором

$$\begin{aligned} (v_i - \lambda u, v_j - \lambda u) &= (v_i, v_j) - \lambda((v_i, u) + (v_j, u)) + \lambda^2(u, u) \leq \\ &\leq \varepsilon - 2\lambda\sqrt{\varepsilon} + \lambda^2 = (\lambda - \sqrt{\varepsilon})^2 \leq 0, \end{aligned}$$

Видно, что всё подобрано так, что годится $\lambda = \sqrt{\varepsilon}$. Теорема Джонсона доказана.

Аналогичная (но более сложно доказываемая) оценка имеет место и для кодов над q -буквенным алфавитом, только надо заменить $1/2$ на $(q-1)/q$ и увеличить константу при n в оценке для размера списка.

24 Оценка Элиаса – Бассалыго

Оценку Джонсона можно использовать для улучшения границы Гильберта. Напомним, что она получалась так: если код имеет расстояние d , то шары радиуса $d/2$ с центрами в кодовых словах не пересекаются, и потому их суммарный объём не больше объёма всего пространства.

Теперь мы возьмём шары большего радиуса, чем $d/2$. Про них уже нельзя утверждать, что пересечений нет. Однако — при подходящем радиусе — оценка Джонсона позволяет утверждать, что любая точка z покрыта небольшим числом шаров (поскольку шар с центром z содержит небольшое число кодовых слов). Поэтому суммарный объём шаров превосходит объём всего пространства в небольшое число раз.

Конкретно: пусть код со словами длины n в двухбуквенном алфавите имеет расстояние $d = \frac{1}{2}(1 - \varepsilon)n$. Шары радиуса $\frac{1}{2}(1 - \sqrt{\varepsilon})$ могут пересекаться, но кратность пересечений не превосходит $2n$. Получаем неравенство

$$2^k V_2(\frac{1}{2}(1 - \sqrt{\varepsilon})n) \leq 2n \cdot 2^n,$$

для кодов с расстоянием

$$d = \frac{1}{2}(1 - \varepsilon)n$$

Переходя к логарифмам, используя приближённую формулу для V_2 (с шенноновской энтропией), деля на n и пренебрегая множителем $2n$ (малым по сравнению с 2^n при больших n), получаем асимптотическую границу, показанную на рис. 3 пунктирной линией. Эта граница называется *границей Элиаса – Бассалыго*.

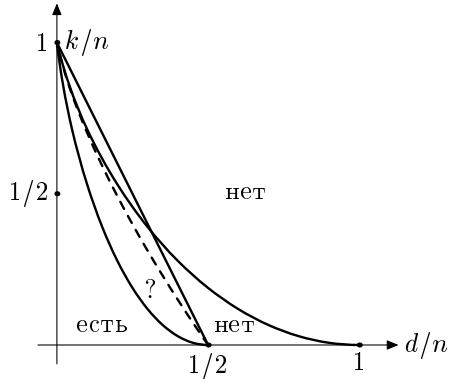


Figure 3: Граница Элиаса – Бассалыго.

25 Декодирование списком кодов Рида – Соломона

Пусть $\Sigma = \mathbb{F}_q$ — конечное поле из q элементов. Код Рида – Соломона кодирует многочлен степени меньше k (то есть набор из k его коэффициентов) значениями этого многочлена в n точках поля. Кодовое расстояние для такого кода равно $n - k + 1$, поэтому для восстановления многочлена по (испорченному) набору значений достаточно иметь примерно $(n + k)/2$ правильных значений в этом наборе.

Как мы видели, для декодирования списком (полиномиального размера) достаточно иметь примерно \sqrt{nk} правильных значений. Сейчас мы дадим новое доказательство этого факта, из которого можно извлечь алгоритм декодирования.

Идея доказательства: при декодировании кода Рида – Соломона мы искали многочлены $D(x)$ и $Q(x)$, для которых пары (x_i, y_i) (точки и значения в этих точках) ложатся на кривую $D(x)y - Q(x) = 0$. Другими словами, мы искали многочлен $R(x, y)$ степени 1 по переменной y , который обращается в нуль в этих точках, а затем доказывали, что $Q(x)$ делится на $D(x)$ и многочлен $R(x, y)$ представляется в виде $D(x)(y - P(x))$, где $P(x)$ — частное от деления Q на D — искомый ответ.

Сейчас мы будем делать то же самое, но с двумя отличиями:

- многочлен R уже не обязательно первой степени по y ;
- мы будем требовать не просто обращения в нуль выражения $R(x_i, y_i)$, а обращения в нуль с некоторой кратностью a_i .

Говорят, что многочлен $R(x, y)$ обращается в нуль в точке (a, b) с кратностью t , если $R(a + u, b + v)$ как многочлен от u и v не имеет членов степени меньше t . Кратность 1 означает просто $R(a, b) = 0$, кратность 2 означает, что и производные по x и y равны нулю, кратность 3 — обраще-

ние в нуль вместе со вторыми производными и так далее.

Заметим, что обращение в нуль в данной точке есть линейное условие на коэффициенты многочлена R ; обращение в нуль с кратностью m представляет собой набор из $1 + 2 + \dots + m = m(m+1)/2$ условий. Тем самым мы можем подобрать искомый многочлен R методом неопределённых коэффициентов, если только этих коэффициентов больше, чем условий во всех точках. Если при этом степень многочлена R будет не слишком велика, то его обращение в нуль на многих точках кривой $y = P(x)$ (где P — исходный многочлен) гарантирует, что он обращается в нуль на всей этой кривой.

Чтобы сформулировать точное утверждение, определим *k*-взвешенную степень многочленов в $\mathbb{F}_q[x, y]$: моном $x^u y^v$ имеет степень $u + kv$; степень многочлена — наибольшая из степеней мономов. (Переменная y считается имеющей вес k , поскольку мы собираемся на её место подставлять многочлен степени k .)

Следующие леммы носят чисто алгебраический характер.

Лемма 1. Пусть x_1, \dots, x_n и y_1, \dots, y_n — произвольные элементы поля \mathbb{F}_q . Пусть a_1, \dots, a_n — произвольные натуральные числа. Если a — натуральное число, для которого

$$a^2 > k \sum_{i=1}^n a_i(a_i + 1),$$

то существует ненулевой многочлен $R(x, y)$, который имеет *k*-взвешенную степень меньше a и который обращается в нуль в точке (x_i, y_i) с кратностью a_i (при всех $i = 1, \dots, n$).

Доказательство. Размерность пространства многочленов, имеющих *k*-взвешенную степень меньше a , равна числу решений неравенства

$$u + kv < a$$

в целых числах $u, v \geq 0$. А это число не меньше площади треугольника, ограниченного прямыми $u + kv \leq a$, $u \geq 0$, $v \geq 0$, которая равна $a^2/2k$ (половина произведения катетов a и a/k). В самом деле, если нарисовать этот треугольник на клетчатой бумаге и взять любую точку (u, v) внутри него (не на границе), то эта точка попадает в клетку с левым нижним углом $(\lfloor u \rfloor, \lfloor v \rfloor)$. Координаты этого левого нижнего угла целые и удовлетворяют неравенству, поэтому число целых решений неравенства не меньше площади треугольника (ведь он покрыт клетками).

Поэтому размерность пространства многочленов, имеющих *k*-взвешенную степень меньше a , не меньше $a^2/2k$. С другой стороны, число линейных условий, выражающих обращение в нуль многочлена R в точках (x_i, y_i) с кратностью a_i , равно

$$\sum_{i=1}^n \frac{a_i(a_i + 1)}{2},$$

что по условию леммы меньше размерности пространства многочленов.

Лемма 2. Пусть x_1, \dots, x_n и y_1, \dots, y_n — произвольные элементы поля \mathbb{F}_q . Пусть a_1, \dots, a_n — произвольные натуральные числа. Пусть многочлен $R(x, y)$ имеет k -взвешенную степень меньше a и обращается в нуль в точке (x_i, y_i) с кратностью a_i (при всех $i = 1, \dots, n$). (Пока всё как в лемме 1.) Пусть, наконец, многочлен $P(x)$ имеет степень не больше k и

$$\sum \{a_i \mid P(x_i) = y_i\} \geq a$$

(сумма весов точек (x_i, y_i) , через которые проходит его график, не меньше a). Тогда $R(x, P(x))$ является нулевым многочленом (равен нулю в кольце многочленов от одной переменной).

Доказательство. Многочлен $N(x) = R(x, P(x))$ (как многочлен от одной переменной x) имеет степень меньше a . Если (x_i, y_i) является корнем $R(x, y)$ кратности m , а $P(x_i) = y_i$, то многочлен $N(x)$ имеет корень x_i кратности m . Поэтому у многочлена N число корней с учётом кратности не меньше a , а степень меньше a . Следовательно, $N = 0$, что и утверждает лемма.

Лемма 3. Пусть $R(x, y)$ — многочлен от двух переменных, а $P(x)$ — от одной переменной, причём $R(x, P(x)) = 0$. Тогда $R(x, y)$ делится на многочлен $y - P(x)$ в кольце многочленов от двух переменных.

(Равенство $R(x, P(x)) = 0$ понимается как равенство в кольце многочленов, то есть как равенство нулю всех коэффициентов; это, вообще говоря, более сильное утверждение, чем равенство во всех точках, если элементов в основном поле мало.)

Доказательство. Рассмотрим $R(x, y)$ как многочлен от y , коэффициенты которого являются многочленами от x , и разделим его уголком на $y - P(x)$. Поскольку старший коэффициент делителя равен единице, при этом не появится никаких дробей, частное будет многочленом от x и y , а остаток — многочленом от x (поскольку делитель имеет степень 1 по y , остаток имеет степень 0 по y). Таким образом,

$$R(x, y) = (y - P(x))Q(x, y) + S(x).$$

Подставив теперь $P(x)$ вместо y , получим, что $S(x)$ — нулевой многочлен, что и требовалось доказать.

Теперь всё готово, чтобы вернуться к декодированию списком. Пусть имеется n точек (x_i, y_i) . Нас интересует, сколько различных многочленов степени не больше k могут проходить через s из них (для данных n, k и s).

Чтобы оценить это число, рассмотрим целое положительное N (пока произвольное) и положим $a_1 = a_2 = \dots = N$. (Кажется странным, зачем вообще нужны кратности, если они все равны. Тем не менее, как мы увидим, это полезно.)

Чтобы применить лемму 1, нужно выбрать натуральное a , для которого

$$a^2 > k \sum_{i=1}^n a_i(a_i + 1) = knN(N + 1),$$

то есть

$$a > \sqrt{knN(N+1)}$$

Применение леммы 1 даёт многочлен $R(x, y)$, имеющий k -взвешенную степень меньше a и обращающийся в нуль с кратностью N во всех точках (x_i, y_i) .

Если многочлен P имеет степень не выше k и проходит через s точек из числа (x_i, y_i) , причём

$$sN \geq a,$$

то $R(x, P(x)) = 0$ по лемме 2 и $R(x, y)$ делится на $y - P(x)$ по лемме 3.

Из курса алгебры известно, что в кольце $\mathbb{F}_q[x, y]$ разложение на множители однозначно, так что число делителей вида $y - P(x)$ у многочлена $R(x, y)$ меньше a/k (иначе суммарная k -взвешенная степень произведения достигнет a , ведь y имеет взвешенную степень k).

Собирая всё вместе (считая a равным sN и поделив обе части неравенства на N) получаем такое утверждение:

Теорема. Если

$$s > \sqrt{kn(1 + 1/N)},$$

то количество различных многочленов P степени не выше k , проходящих через s или более точек среди $(x_1, y_1), \dots, (x_n, y_n)$, меньше sN/k .

Видно, что эта теорема применима при $s > \sqrt{nk}$; чем ближе это неравенство к равенству, тем большее N придётся брать (и тем слабее будет оценка на число различных многочленов). Ещё из неё видно, например, что при $s = (1 + \varepsilon)\sqrt{nk}$ и $n = O(k)$ число различных многочленов P степени меньше k , проходящих через s точек из n , есть $O(1)$.

В следующем разделе нам потребуется аналогичное утверждение для случая произвольных весов:

Теорема. Пусть x_1, \dots, x_n и y_1, \dots, y_n — произвольные элементы поля \mathbb{F}_q . Пусть a_1, \dots, a_n — произвольные натуральные числа. Пусть натуральные числа k и a таковы, что

$$a^2 > k \sum_{i=1}^n a_i(a_i + 1).$$

Тогда количество многочленов $P(x)$ степени не выше k , для которых набираемый ими вес

$$\sum \{a_i \mid P(x_i) = y_i\}$$

не меньше a , меньше a/k .

В самом деле, по лемме 1 можно найти многочлен $R(x, y)$, обращающийся в нуль в (x_i, y_i) с кратностью a_i и имеющий k -взвешенную степень меньше a ; по лемме 2 выполнено равенство $R(x, P(x)) = 0$ для любого многочлена степени не выше k , набирающего вес не меньше a ; по лемме 3 $R(x, y)$ делится на $y - P(x)$ для всех этих многочленов и потому их число меньше a/k .

Приведённое доказательство после некоторого дополнительного анализа позволяет построить полиномиальный алгоритм декодирования списком для кодов Рида – Соломона. Надо только научиться раскладывать на множители многочлены в $\mathbb{F}_q[x, y]$ или хотя бы выделять из них все множители вида $y - P(x)$.

26 Рид – Соломон плюс Адамар: декодирование списком

Рассматривая код Адамара в разделе 15, мы уже упоминали о возможности использовать его в качестве внутреннего кода, когда внешним является код Рида – Соломона. Сейчас мы используем методы предыдущего раздела (декодирование кода Рида – Соломона с весами), чтобы получить алгоритм декодирования списком для такого каскадного кода.

Напомним параметры рассматриваемого кода. Мы рассматриваем поле \mathbb{F}_{2^m} из 2^m элементов, которые мы обозначим x_1, \dots, x_{2^m} . Внешний код Рида – Соломона кодирует $\varepsilon 2^m$ элементов поля, рассматривая их как коэффициенты многочлена P степени меньше $\varepsilon 2^m$ и беря значения $P(x_1), \dots, P(x_{2^m})$. Внутренний код Адамара кодирует каждое из этих значений (то есть слово из m битов) словом из 2^m битов.

Результирующий каскадный код кодирует слово из $\varepsilon m 2^m$ битов, разбивая его на $\varepsilon 2^m$ блоков по m битов, и затем заменяя каждый блок на его код Адамара. Получается 2^m блоков по 2^m битов в каждом, всего 2^{2m} битов.

Кодовое расстояние (удельное, в расчёте на бит кодового слова) для внешнего кода равно $1 - \varepsilon$, а для внутреннего равно $1/2$, поэтому для конкатенации оно равно $\frac{1}{2}(1 - \varepsilon)$.

Оценка Джонсона говорит теперь, что декодирование списком возможно с долей ошибок $\frac{1}{2}(1 - \sqrt{\varepsilon})$ и длиной списка $2 \cdot 2^{2m}$ (удвоенная длина кодового слова). Покажем, что такой список можно получить с помощью описанной в предыдущем разделе техники (набором весов вдоль алгебраической кривой).

Итак, пусть имеется некоторое слово z длины 2^{2m} , для которого мы хотим составить список близких к нему кодовых слов. Разобьём слово z на 2^m блоков z_1, \dots, z_{2^m} длины 2^m каждый. Как и раньше, декодирование каскадного кода начинается с декодирования каждого блока по отдельности. Но в данном случае мы не будем выбирать какого-то одного варианта декодирования, а рассмотрим все возможные варианты. А именно, для каждого блока z_i и для любого элемента x_j поля \mathbb{F}_{2^m} посмотрим, насколько близко слово z_i к коду Адамара элемента x_j . Оба сравниваемых слова имеют длину 2^m , и мы вычтем число несовпадений из числа совпадений; разность мы будем называть весом и обозначать a_{ij} . Если $a_{ij} < 0$ (несовпадений больше, чем совпадений) то такой вариант декодирования (z_i получилось искажением кода элемента x_j) мы сразу же отвергнем. Для всех оставшихся вариантов веса a_{ij} неотрицательны. Получается максимум 2^{2m}

неотрицательных весов, поскольку каждый из индексов i, j пробегает 2^m значений (соответствующих 2^m элементам поля).

Эти веса будут использованы при декодировании внешнего кода. Мы будем проводить алгебраическую кривую через все точки $(x_i, x_j) \in \mathbb{F}_{2^m}^2$, у которых веса $a_{i,j}$ неотрицательны. (Заметим, что теперь у нас есть много точек с одинаковой первой координатой, чего раньше не было.) В обозначениях последней теоремы предыдущего раздела:

$$q = 2^m, \quad n \leq 2^{2m}, \quad k = \varepsilon 2^m.$$

Остаётся понять, каким должно быть значение a . Чем оно больше, тем утверждение теоремы слабее, поэтому его надо взять минимально возможным, для которого

$$a^2 > k \sum_{i=1}^n a_i(a_i + 1) = \varepsilon 2^m \sum_{i,j} a_{ij}(a_{ij} + 1).$$

(в левой части равенства используются обозначения предыдущего раздела, а справа подставлены их текущие значения). Правую часть можно записать как

$$\varepsilon 2^m \left[\sum_{i,j} a_{ij}^2 + \sum_{i,j} a_{ij} \right].$$

Второе (меньшее) слагаемое оценим сверху, заменив все a_{ij} на их максимально возможное значение 2^m , получится $\varepsilon 2^{4m}$. Первое слагаемое будем оценивать более деликатным способом. Сгруппируем слагаемые с одним и тем же i (соответствующие одному блоку в конкатенации, но разным вариантам его декодирования), получим

$$\varepsilon 2^m \sum_i \left[\sum_j a_{ij}^2 \right].$$

Теперь оценим отдельно каждую квадратную скобку (при фиксированном j). Вес a_{ij} представляет собой скалярное произведение кода Адамара элемента x_j и слова z_i , взятое с множителем 2^m (скажем, если скалярное произведение равно 1, то есть имеет место полное совпадение, вес равен 2^m). Остается вспомнить про неравенство Бесселя (= теорему Пифагора), согласно которому сумма квадратов скалярных произведений единичного вектора с векторами ортонормированного базиса не превосходит 1. После учёта коэффициентов это даёт

$$\varepsilon 2^m \sum_i \left[\sum_j a_{ij}^2 \right] \leq \varepsilon 2^m \sum_i 2^{2m} = \varepsilon 2^m \cdot 2^m \cdot 2^{2m} = \varepsilon 2^{4m}$$

Таким образом, для применения теоремы из предыдущего раздела достаточно неравенства

$$a^2 > \varepsilon 2 \cdot 2^{4m},$$

то есть

$$a > \sqrt{2\varepsilon} 2^{2m}.$$

Таким образом, количество многочленов степени не выше $\varepsilon 2^m$, набирающих вес a или больше, невелико. Остаётся понять, что суммарный вес, набираемый многочленом, есть разница между суммарным числом совпадений и несовпадений в соответствующем кодовом слове, и тем самым можно выложить все кодовые слова, для которых эта разница между числом совпадений и несовпадений больше

$$\sqrt{2\varepsilon} 2^{2m},$$

то есть в расчёте на бит больше $\sqrt{2\varepsilon}$. Поскольку эта разница есть $1 - 2d$, где d — доля ошибок, условие на d будет таким:

$$d < \frac{1}{2}(1 - \sqrt{2\varepsilon}).$$

При этом число кодовых слов в списке оценивается величиной

$$a/k = \sqrt{2\varepsilon} 2^{2m} / (\varepsilon 2^m),$$

что по порядку величины равно 2^m , то есть корню из длины кодового слова (немного лучше, чем в оценке Джонсона).

Зато у нас вместо $\sqrt{\varepsilon}$, как в оценке Джонсона, появляется $\sqrt{2\varepsilon}$. В основном это из-за того, что мы очень грубо оценивали сумму первых степеней. Сделаем это точнее: при каждом i у нас имеется сумма 2^m чисел, сумма квадратов которых не превосходит 2^{2m} , так что их среднее квадратичное не превосходит $2^{m/2}$. Среднее арифметическое не больше среднего квадратичного, поэтому сумма $\sum_j a_{ij}$ не больше $2^{3m/2}$ (а раньше мы её оценивали как 2^{2m} , так что есть заметное улучшение).

Отсюда ясно, что константу 2 в $\sqrt{2\varepsilon}$ можно (для достаточно больших m) заменить на сколь угодно близкую к единице.

27 Вероятностное декодирование списком для кодов Адамара

Ещё один результат, связанный с кодами Адамара — теорема Голдрайха и Левина о вероятностном декодировании списком (первоначальная формулировка была в терминах вычислительной криптографии, но по существу она именно об этом).

Теорема. Пусть $\alpha < 1/2$ и $\varepsilon > 0$. Существует вероятностный полиномиальный алгоритм, который по данному t и по данному слову g длины 2^m указывает список полиномиальной длины, который с вероятностью не менее $1 - \varepsilon$ содержит все кодовые слова кода Адамара, отличающиеся от g не более чем в $\alpha 2^m$ позиций.

Эта формулировка требует трёх уточнений. Во-первых, полиномиальность означает, что время работы алгоритма (во всех случаях) ограничено

некоторым полиномом от m . Во-вторых, слово g (имеющее длину 2^m) подаётся на вход алгоритма в виде “оракула” (алгоритм может запросить значение любого бита, указав его номер, то есть слово рассматривается как функция $g: \mathbb{B}^m \rightarrow \mathbb{B}$, и алгоритм может её “вызывать”). В третьих, алгоритм указывает не сами кодовые слова кода Адамара (они имеют экспоненциальную длину, и за полиномиальное от m время их выписать нельзя), а их прообразы при кодировании (то есть слова из $m + 1$ битов, которые являются коэффициентами соответствующей аффинной функции).

Доказательство. Будем считать, что $\alpha = \frac{1}{2} - \delta$ при некотором $\delta > 0$.

Для доказательства теоремы мы построим алгоритм \mathcal{B} , получающий на вход рациональные числа $\delta, \varepsilon > 0$, натуральное число m и (в виде оракула) функцию $g: \mathbb{B}^m \rightarrow \mathbb{B}$, и выдающий список $\mathcal{B}(\delta, \varepsilon, m, g)$ аффинных функций (то есть их коэффициентов). При этом алгоритм будет полиномиальным от $m, 1/\delta$ и $1/\varepsilon$, если δ и ε достаточно просты, так что длины их записей ограничены полиномом от $1/\delta$ и $1/\varepsilon$ (это заведомо так, если они обратны к целым числам, и в дальнейшем мы рассматриваем только такие ε и δ).

Основное свойство этого алгоритма:

Лемма. Пусть $f: \mathbb{B}^m \rightarrow \mathbb{B}$ — аффинная функция, а $g: \mathbb{B}^m \rightarrow \mathbb{B}$ — произвольная функция, отличающаяся от f не более чем в $(\frac{1}{2} - \delta)$ -доле аргументов. Тогда вероятность того, что f войдёт в список $\mathcal{B}(\delta, \varepsilon, m, g)$, не меньше $1 - \varepsilon$.

Прежде чем доказывать лемму, поясним её связь с исходной формулировкой теоремы. Лемма говорит о вероятности покрыть списком одну аффинную функцию, близкую к g ; в теореме мы говорили о покрытии всех таких функций. Но поскольку таких функций мало (что следует из свойств кода Адамара — при данном δ их не больше некоторой константы), то вероятность при переходе от леммы к теореме возрастёт не сильно. (Кстати, тот факт, что функций немного, следует из леммы — если бы их было много, то список полиномиального размера, выдаваемый алгоритмом, не мог с высокой вероятностью покрывать любую из них.)

Доказательство леммы. Итак, в роли алгоритма \mathcal{B} мы имеем доступ к g — “искажённому варианту” неизвестной аффинной функции

$$f(x_1, \dots, x_m) = f_0 + f_1 x_1 + \dots + f_m x_m,$$

и должны отгадать коэффициенты f_0, \dots, f_m . Эти коэффициенты определяются значениями f в $m + 1$ точках

$$(0, 0, \dots, 0), (1, 0, \dots, 0), (0, 1, \dots, 0), \dots, (0, 0, \dots, 1)$$

(и наоборот), и нам будет удобнее говорить о отгадывании этих значений. (На самом деле конкретный вид точек нам не важен, мы можем отгадывать значения в произвольных $m + 1$ точках — и даже в произвольном полиномиальном числе точек.)

Поскольку функция f является аффинной, то для любых x и r из \mathbb{B}^m выполняется равенство

$$f(x) = f(x + r) - \bar{f}(r),$$

где \bar{f} — линейная часть f (без f_0). Пусть x фиксировано, а r пробегает \mathbb{B}^m . Поскольку f и g совпадают по крайней мере в $(\frac{1}{2} + \delta)$ -доле позиций (что больше половины), то

$$f(x) = \text{большинство из } [g(x+r) - \bar{f}(r)],$$

и это большинство можно определить методом Монте-Карло, выбрав несколько случайных r и проведя голосование среди выбранных значений.

План этот на первый взгляд не имеет смысла, так как в правой части стоит $\bar{f}(r)$, которого мы всё равно не знаем (ведь \bar{f} отличается от f лишь отсутствием коэффициента f_0).

Заметим, однако, что для нахождения большинства по методу Монте-Карло не обязательно, чтобы испытания были по-настоящему независимы. Достаточно (хотя и с худшой оценкой на вероятность ошибки), чтобы они были *попарно* независимы. Именно, имеет место

Закон больших чисел для попарно независимых событий. Пусть события A_1, \dots, A_N попарно независимы и каждое из них имеет вероятность меньше $\frac{1}{2} - \delta$. Тогда вероятность того, что произойдёт половина или больше событий, не превосходит

$$\frac{1}{\delta^2} \cdot \frac{1}{N}$$

(и потому мала при больших N).

В самом деле, рассмотрим индикаторы этих событий (случайные величины a_i , равные единице, если A_i случилось, и нулю в противном случае). Математическое ожидание каждого из индикаторов не больше $\frac{1}{2} - \delta$. Поэтому математическое ожидание суммы не больше $N(\frac{1}{2} - \delta)$. Теперь воспользуемся попарной независимостью: она гарантирует, что дисперсия суммы $\sum a_i$ равна сумме дисперсий; дисперсия a_i не превосходит 1 (на самом деле даже $1/4$), поэтому дисперсия суммы не превосходит N . Дисперсия есть математическое ожидание квадрата отклонения от математического ожидания. Если произойдёт больше половины событий, то отклонение будет по крайней мере $N\delta$, а его квадрат — $N^2\delta^2$. Поэтому по неравенству Чебышёва вероятность такого события не больше

$$\frac{N}{N^2\delta^2} = \frac{1}{\delta^2} \cdot \frac{1}{N},$$

что и требовалось доказать.

Откуда мы возьмём попарно независимые величины? Если взять s (полностью) независимых векторов в \mathbb{B}^m , то их частичные суммы (всего $2^s - 1$ векторов) будут попарно независимы. Например, если u_1, u_2 и u_3 — (полностью) независимые векторы, то семь векторов

$$u_1, u_2, u_3, u_1 + u_2, u_1 + u_3, u_2 + u_3, u_1 + u_2 + u_3$$

будут попарно независимы. (Скажем, при данном значении $u_1 + u_2$ все значения $u_1 + u_3$ равновероятны, поскольку u_3 не зависит от пары (u_1, u_2) .)

Геометрически: на s случайных независимых равномерно распределённых векторов мы натягиваем параллелепипед, и $2^s - 1$ его вершин (не считая нулевой) будут попарно независимы.

Теперь уже можно объяснить идею доказательства: мы положим

$$f(x) = \text{большинство из } [g(x + r_i) - \bar{f}(r_i)],$$

где r_i — попарно независимые векторы ($2^s - 1$ штук), а именно, ненулевые вершины параллелепипеда, натянутого на (полностью) независимые векторы u_1, \dots, u_s . Чтобы получить малую вероятность ошибки, достаточно взять полиномиальное число попарно независимых векторов, то есть $2^s - 1 = \text{poly}(m)$, а тогда $s = O(\log m)$. (Это — для фиксированных ε и δ , оценку для общего случая см. ниже.)

Теперь главное: все значения $\bar{f}(r_i)$ в силу линейности \bar{f} определяются значениями $\bar{f}(u_1), \dots, \bar{f}(u_s)$, то есть s битами. Возможных вариантов этих значений 2^s , то есть полиномиальное от m количество. Вспомним, что нам разрешалось отгадывать с нескольких попыток: алгоритм \mathcal{B} выдаёт не один набор коэффициентов, а полиномиальный (от m) список вариантов. Так что нам позволено перепробовать эти варианты, и всё сходится.

Оценим возникающие вероятности более подробно. Нам нужно восстановить значения f в $m + 1$ точках. Мы начинаем с того, что выбираем независимые векторы u_1, \dots, u_s и получаем из них попарно независимые векторы $r_1, \dots, r_{2^s - 1}$. Затем для каждой из $m + 1$ точек мы проводим голосование с $2^s - 1$ участниками и получаем набор из $m + 1$ предполагаемых значений. Эта процедура предполагает известными значения $\bar{f}(u_1), \dots, \bar{f}(u_s)$ и проводится 2^s раз, для всех возможных вариантов. Подчеркнём, что выбор случайных векторов u_1, \dots, u_s производится только один раз: одни и те же векторы используются для всех $m + 1$ точек и во всех 2^s попытках.

Для данной точки x события $f(x + r_i) \neq g(x + r_i)$ (при $i = 1, 2, \dots, 2^s - 1$), всего $2^s - 1$ событий) являются попарно независимыми. Вероятность каждого из них не больше $\frac{1}{2} - \delta$. Поэтому вероятность того, что выборка окажется “плохой” (не меньше половины попаданий в ошибки, где $f \neq g$), не превосходит

$$\frac{1}{\delta^2} \cdot \frac{1}{2^s - 1}.$$

Это — для данной точки x ; вероятность того, что выборка окажется плохой хотя бы для одной из $m + 1$ точек, не больше

$$\frac{1}{\delta^2} \cdot \frac{1}{2^s - 1} \cdot (m + 1)$$

и потому меньше ε , если

$$2^s > \frac{m + 1}{\varepsilon \delta^2} + 1.$$

А если выборка хороша для всех $m + 1$ точек, то в список, выдаваемый алгоритмом \mathcal{B} (и содержащий 2^s вариантов), войдёт и правильный ответ (коэффициенты аффинной функции f). Длина списка и время работы алгоритма \mathcal{B} при этом полиномиальны от $(m + 1)/\varepsilon \delta^2 + 1 = \text{poly}(m, 1/\varepsilon, 1/\delta)$.