


Лекция

22–23 декабря

# Сжатие и границы

# Код Хаффмана и границы



*Основная задача связи состоит в точном или приближенном воспроизведении в некотором месте сообщения, выбранного для передачи в другом месте.*

*— Клод Шеннон*

## Защита и сжатие

Код Хэмминга защищает от ошибок, добавляя избыточность.

Код Хаффмана решает обратную задачу — сжать данные до минимального размера без потерь.

Частым символам — короткие кодовые слова, редким — длинные.

Азбука Морзе делает то же самое: буква E — одна точка, а Q — четыре знака.

# Префиксный код

## Определение 1 (Префиксный код)

Код называется **префиксным**, если ни одно кодовое слово не является началом другого.

## Пример

Код  $\{0, 10, 11\}$  префиксный: ни одно слово не начало другого.

Код  $\{0, 01, 011\}$  нет: слово 0 может продолжиться как 01 или как 011 — декодер не знает, кончилось ли слово.

## Декодирование без задержки

### Пример

Слова  $A = 0$ ,  $B = 10$ ,  $C = 110$ ,  $D = 1110$ ,  $E = 1111$ .

Поток 1101111 читается слева направо: 110 — это  $C$ , сразу за ним 1111 — это  $E$ .

Другого разбиения нет: конец слова виден в момент прочтения.

Префиксность устраняет неоднозначность: декодер не возвращается и не ждёт.

# Алгоритм Хаффмана


Алгоритм жадный и строит дерево снизу вверх.

## Пример

Частоты:  $A = 0.40$ ,  $B = 0.25$ ,  $C = 0.20$ ,  $D = 0.10$ ,  $E = 0.05$ .

1. Сливаем два наименьших веса:  $D$  и  $E$  — узел 0.15.
2. Дальше  $C$  и  $DE$  — узел 0.35.
3. Дальше  $B$  и  $CDE$  — узел 0.60.
4. Наконец  $A$  и  $BCDE$  — корень 1.00.

# Дерево Хаффмана



Путь от корня к листу — кодовое слово: левый переход даёт 0, правый — 1.

Кодовые слова:  $A = 0$ ,  $B = 10$ ,  $C = 110$ ,  $D = 1110$ ,  $E = 1111$ .

## Средняя длина

### Определение 2 (Средняя длина кода)

$$L = \sum_i f_i l_i,$$

где  $f_i$  — частота символа,  $l_i$  — длина его слова.

### Пример

$$L = 0.40 \cdot 1 + 0.25 \cdot 2 + 0.20 \cdot 3 + 0.10 \cdot 4 + 0.05 \cdot 4 = 2.10$$

бита на символ — против  $\lceil \log_2 5 \rceil = 3$  битов у равномерного кода на пять символов.

# Оптимальность

## Теорема 1 (Оптимальность кода Хаффмана)

Для заданных частот код Хаффмана имеет минимальную среднюю длину среди всех префиксных кодов.

- Идея доказательства — обменный аргумент: два редчайших символа можно обменять с любыми соседними листьями максимальной глубины, и средняя длина не вырастет.
- Код Хаффмана не единственный: паре сливаемых поддеревьев нули и единицы раздаются свободно, а при равных весах оптимальных деревьев несколько.

## Словарное сжатие: LZ77 и LZ78

Хаффман видит только частоты, а главный резерв реальных данных — повторения.

Словарное сжатие заменяет повтор ссылкой: канал передаёт адрес, а не копию.

### Определение 3 (Тройка LZ77)

Кодер ищет совпадения в *скользящем окне* — уже закодированном хвосте входа.

Повтор кодируется тройкой  $(o, l, a)$ : смещение назад, длина совпадения, первый несовпавший символ.

LZ78 копит *словарь фраз* вместо окна: выход — пары из номера фразы и нового символа.

DEFLATE (gzip, zip, PNG) — LZ77 плюс код Хаффмана: LZ выучивает повторения, Хаффман ужимает остаток.

## Сколько кодов вообще возможно?

Исправление ошибок — это упаковка шаров в двоичном кубе.

### Теорема 2 (Граница Хэмминга)

Если код исправляет  $t$  ошибок, то

$$|C| \cdot \sum_{i=0}^t \binom{n}{i} \leq 2^n.$$

Объём шара радиуса  $t$  — число строк на расстоянии не больше  $t$ :  $\sum_{i=0}^t \binom{n}{i}$ .

### Доказательство

Шары радиуса  $t$  вокруг кодовых слов не пересекаются, и все они лежат в кубе из  $2^n$  строк.

## Совершенный код

### Пример

Для кода Хэмминга  $(7, 4)$  объём шара радиуса 1 равен  $1 + 7 = 8$ .

$$16 \cdot 8 = 128 = 2^7.$$

Шары покрывают всё пространство без зазоров.

Код, достигающий границы Хэмминга, называется **совершенным**.

Код Хэмминга  $(7, 4)$  — совершенный.

# Энтропия

## Определение 4 (Энтропия)

Для символов с вероятностями  $p_1, \dots, p_n$ :

$$H = - \sum_{i=1}^n p_i \log_2 p_i.$$

## Пример

Два равновероятных символа:  $H = 1$  бит.

Достоверный символ ( $p = 1$ ):  $H = 0$  — сообщать не о чем.

Энтропия — минимум среднего числа битов на символ: любой префиксный код имеет  $L \geq H$ .

## Пропускная способность канала

Канал передаёт биты и с вероятностью  $p$  переворачивает каждый независимо — двоичный симметричный канал.

### Определение 5 (Пропускная способность)

$$C = 1 - H(p) = 1 + p \log_2 p + (1 - p) \log_2 (1 - p).$$

| $p$ | $C$  | Канал         |
|-----|------|---------------|
| 0   | 1    | без ошибок    |
| 0.1 | 0.53 | умеренный шум |
| 0.2 | 0.28 | шум заметен   |
| 0.5 | 0    | бесполезен    |

При  $p = 0.5$  принятый бит не зависит от переданного — канал не несёт ничего.

# Теорема Шеннона

## Теорема 3 (Теорема Шеннона о кодировании (1948))

При любой скорости  $R < C$  существуют коды с вероятностью ошибки, стремящейся к нулю.

При любой скорости  $R > C$  надёжная передача невозможна.

Доказательство неконструктивно: случайный код большой длины хорош с высокой вероятностью, но из доказательства не извлечь сам код.

Построение явных кодов у границы — программа на семь десятилетий: Рид—Соломон, турбо-коды, LDPC, полярные коды.

## Сжать, потом защитить

Защита и сжатие двигают одну величину — долю полезного в переданном.

Данные сжимают кодом Хаффмана, затем защищают кодом Хэмминга.

Сжатие убирает лишнюю избыточность, канальный код добавляет её назад — дозированно и там, где её ждёт декодер.

## Обзор: циклические коды

### Определение 6 (Циклический код)

Линейный код, замкнутый относительно циклического сдвига:

$$(c_0, \dots, c_{n-1}) \rightarrow (c_{n-1}, c_0, \dots, c_{n-2}).$$

Слово — многочлен  $c(x) = c_0 + c_1x + \dots + c_{n-1}x^{n-1}$ , а сдвиг — умножение на  $x$  по модулю  $x^n - 1$ .

Кодовые слова — в точности кратные порождающего многочлена  $g(x)$ , который делит  $x^n - 1$ .

## Деление с остатком

### Пример

Для кода  $(7, 4)$ :  $g(x) = 1 + x + x^3$ .

Проверка над  $\text{GF}(2)$ :

$$x^7 - 1 = (1 + x + x^3)(1 + x + x^2 + x^4).$$

Удвоенные члены обнуляются:  $x^i + x^i = 0$ .

Кодирование:  $c(x) = x^{n-k}m(x) - r(x)$ , где  $r(x)$  — остаток от деления на  $g(x)$ .

Декодирование — то же деление: ненулевой остаток — сигнал об ошибке.

## CRC в Ethernet

1. Отправитель вычисляет остаток  $r(x)$  от деления данных на  $g(x)$  и дописывает его в конец пакета.
2. Получатель делит принятое на  $g(x)$ : ненулевой остаток — ошибка.
3. CRC-32 живёт в Ethernet, PNG и gzip.

CRC обнаруживает, но не исправляет: повреждённый пакет отбрасывается, а доставку берёт на себя транспортный уровень.

## Обзор: коды Рида—Соломона

### Определение 7 (Код Рида—Соломона)

Над полем  $\text{GF}(2^8)$  сообщение  $(m_0, \dots, m_{k-1})$  задаёт многочлен степени меньше  $k$ .

Кодовое слово — значения этого многочлена в  $n = 255$  точках поля.

Многочлен степени меньше  $k$  однозначно восстанавливается по любым  $k$  значениям — это интерполяция.

Кодовое расстояние  $d = n - k + 1$ : два разных многочлена совпадают не более чем в  $k - 1$  точках.

## Маленький РС-код

### Пример

$RS(7, 3, 5)$  над  $GF(8)$ , где  $8 = 2^3$ .

Три символа кодируются семью, расстояние  $d = 7 - 3 + 1 = 5$ .

Исправляет до  $\frac{7-3}{2} = 2$  символьных ошибок, хотя каждый символ — 3 бита.

Две символьные ошибки — до шести испорченных битов: алгебра многочлена чинит их одной операцией над символами.

## Пакетные ошибки

Царапина портит биты подряд.

Код Рида—Соломона считает ошибки символами: байт испорчен целиком или нет, и до  $\frac{n-k}{2}$  испорченных символов исправляются.

### Пример

RS(255, 239): скорость  $R = \frac{239}{255} \approx 0.94$ .

Избыточность всего 6% — и до 8 байтовых ошибок исправляются.

## Где живут РС-коды?

- QR-коды — RS над GF(256) с уровнями коррекции от 7% до 30% повреждённой площади.
- CD и DVD — каскад CIRC: два слоя RS с перемежением против царапин и пыли.
- Цифровое телевидение DVB — RS(204, 188): до 8 байтовых ошибок на блок.
- RAID 6 — два проверочных диска: данные выживают при отказе двух дисков разом.

## Лекция 16: что мы поняли?

- Код Хаффмана строит оптимальный префиксный код: частым символам — короткие слова.
- Префиксность даёт однозначное декодирование без задержки.
- Словарное сжатие LZ заменяет повторения ссылками: DEFLATE — это LZ77 плюс Хаффман.
- Граница Хэмминга ограничивает число кодов упаковкой шаров, и код  $(7, 4)$  — совершенный.
- Энтропия  $H$  — минимум битов на символ, а теорема Шеннона делит скорости на возможные и невозможные.
- Циклические коды — алгебра многочленов: CRC в Ethernet обнаруживает ошибки делением на  $g(x)$ .
- Рид—Соломон работает с символами-байтами и чинит пакетные ошибки: QR-коды, диски, RAID.

## Вопросы для самопроверки

1. Постройте код Хаффмана для частот  $(0.4, 0.3, 0.2, 0.1)$  и посчитайте среднюю длину.
2. Почему код  $\{0, 10, 110, 111\}$  префиксный, а  $\{0, 01, 011\}$  — нет?
3. Сожмите «ABRACADABRA» тройками LZ77 с окном в весь уже закодированный префикс. Какая тройка кодирует финальное «ABRA»?
4. Посчитайте энтропию распределения  $(\frac{1}{2}, \frac{1}{4}, \frac{1}{4})$ .
5. Оцените границей Хэмминга число слов кода длины 9, исправляющего две ошибки.
6. Проверьте, что  $g(x) = 1 + x + x^3$  делит  $x^7 - 1$  над  $\text{GF}(2)$ .
7. Сколько байтовых ошибок исправляет  $\text{RS}(255, 239)$ ? Почему он хорош против царапины на диске?

## Чтение и экзамен

---

- m13 — «Код Хаффмана», «Словарное сжатие: LZ77 и LZ78», «Граница Шеннона», «Циклические коды», «Коды Рида—Соломона».
- Последние занятия — 22–23 декабря.
- Экзамен за семестр 1 — в зимнюю сессию (январь). Даты задаёт расписание вуза.

## Семестр 1: что мы прошли?

- Логика и множества — язык, на котором говорят остальные темы.
- Отношения, порядок, функции, счётность — словарь структур и первая встреча с бесконечностью.
- Формальная логика — вывод и семантика: доказательства как объекты, силлогизмы как системы.
- Булева алгебра и схемы — от формул к железу: ДНФ, минимизация, верификация через SAT.
- Коды — избыточность как математика: расстояние, код Хэмминга, код Хаффмана, границы Шеннона.
- Семестр 2: графы, автоматы, машины Тьюринга, комбинаторика и остальное — с февраля.