

1. Пусть $\sum p_i = 1$ и все $p_i > 0$. Определим функцию $h(p) = \sum p_i \log \frac{1}{p_i}$. К чему стремится значение этой функции для следующих последовательностей:

- a) $1/2, 1/4, 1/8, \dots, 1/2^n, 1/2^n$;
 б) $1/3, 1/3, 1/9, 1/9, \dots, 1/3^n, 1/3^n, 1/3^n$?

2. Веса 2 монеток выбираются случайно и независимо среди чисел $1, \dots, 4$. Какова энтропия Шеннона случайной величины, равной результату сравнения на чашечных весах весов первой и второй монетки?

Определение 1

Будем называть кодом функцию $C: \{a_1, \dots, a_n\} \rightarrow \{0, 1\}^*$, сопоставляющую буквам некоторого алфавита кодовые слова. Если любое сообщение, которое получено применением кода C , декодируется однозначно (т.е. только единственным образом разрезается на образы C), то такой код называется однозначно декодируемым. Код называется префиксным (беспрефиксным, prefix-free), если никакое кодовое слово не является префиксом другого кодового слова.

3. Пусть слова c_1, \dots, c_k задают префиксный код, и слова d_1, \dots, d_ℓ образуют префиксный код. Докажите, что слова вида $c_i d_j$ также образуют префиксный код.

4. Докажите, что для любого префиксного кода со множеством кодовых слов a_1, \dots, a_n выполняется следующее неравенство:

$$\sum_{i=1}^n 2^{-|a_i|} \leq 1.$$

5. Докажите, что если есть набор целых чисел ℓ_1, \dots, ℓ_n , удовлетворяющие неравенству

$$\sum_{i=1}^n 2^{-\ell_i} \leq 1,$$

то существует префиксный код с кодовыми словами c_1, \dots, c_n , где $|c_i| = \ell_i$.

Определение 2 (код Шеннона – Фано)

Отсортируем вероятности, $p_1 \geq p_2 \geq \dots \geq p_n$. «Уложим» вероятности p_i в отрезок $[0, 1]$, получая таким образом точки

$$0 \leq p_1 < p_1 + p_2 < \dots < p_1 + p_2 + \dots + p_n \leq 1.$$

Разобьём интервал пополам, и скажем, что все коды, отвечающие точкам слева от разреза, начинаются с нуля, а точкам справа — с единицы. Если отрезок пересекает разрез, и он самый левый (первый), то соответствующий код начинается с 0; если отрезок пересекает разрез и он самый правый (последний), то код начинается с 1. Иначе выбираем ноль или единицу произвольным образом. Продолжаем рекурсивно этот процесс, пока в интервале не останется ровно один отрезок.

6. Докажите, что:

- а) код Шеннона — Фано является префиксным;
- б) если центральный отрезок относить туда, куда попала его большая часть, то кодирование Шеннона — Фано не является сбалансированным (то есть не существует константы d , для которой выполнено $\ell(c_i) \leq -\log p_i + d$ для любых k и любых исходных вероятностей p_1, \dots, p_k);
- с) если центральный отрезок всегда относить к правой половине, то кодирование Шеннона — Фано также не является сбалансированным.
7. Приведите пример такого распределения вероятностей, что код Шеннона–Фано не является оптимальным.

Определение 3 (Арифметическое кодирование)

Назовём стандартным интервалом интервал вида $[0.v_0, 0.v_1)$, где v — некоторая последовательность битов. Уложим вероятности p_i в отрезок $[0, 1]$, получатся точки

$$0 \leq p_1 < p_1 + p_2 < \dots < p_1 + p_2 + \dots + p_n \leq 1.$$

Пусть $(0.v_i, 0.v_{i+1})$ — максимальный стандартный интервал в отрезке

$$[p_1 + p_2 + \dots + p_{i-1}, p_1 + p_2 + \dots + p_i].$$

Тогда сопоставим i -ой букве код v_i . Легко заметить, что код получился префиксным, так как если v_i является префиксом v_j , то интервал $(0.v_i, 0.v_{i+1})$ вложен в интервал $(0.v_j, 0.v_{j+1})$, а такого при построении v_i не может произойти.

8. Докажите, что арифметическое кодирование сбалансировано с константой 2.

