




КОЛМОГОРОВСКАЯ СЛОЖНОСТЬ СЛУЧАЙНЫХ ПОСЛЕДОВАТЕЛЬНОСТЕЙ

Подготовили
Досова Анна
Лемнёв Вадим



Шенноновская энтропия. Проблемы применения к индивидуальным объектам

- Энтропия — мера неопределенности некоторой системы, например, какого-либо эксперимента, который может иметь разные исходы.
- Недостатки подхода Шеннона:
 - Если применить энтропию Шеннона к текстам, то выходит, что количество информации в тексте зависит только от частот символов, но не зависит от их порядка.
 - При таком подходе получается, что два текста: исходный и отсортированный по символам – содержат одинаковое количество информации.

Новизна теории сложности Колмогорова

- В начале 1960-х гг. Колмогоров, Соломонов, Левин и другие ученые сформулировали способ измерения количества информации в конкретных объектах (строках), а не случайных величинах.
- Основная идея теории сложности Колмогорова в том, что сложность строки определяется длиной наикратчайшей компьютерной программы, способной ее выдать.

Колмогоровская сложность

- Пусть F – алгоритм, аргументами и результатами которого являются двоичные слова.
- Слово x является описанием слова y , если $F(x) = y$.
- Сложность слова y относительно F – длина его кратчайшего описания:

$$K_F(y) = \min \{|x|: F(x) = y\}.$$

Колмогоровская сложность

- Пусть у нас есть два способа описания слова F и U .
- Сложности двух алгоритмов отличаются не более, чем на константу, зависящую от F и U , но не зависящую от слова y :

$$| K_F(y) - K_U(y) | \leq c_{F,U}$$

- Говорят, что U лучше F , если существует такая константа $c_{F,U}$, что для всех y выполняется следующее неравенство:

$$K_U(y) \leq K_F(y) + c_{F,U}$$

- При этом U является оптимальным способом описания слова y .
- Сложность K_U относительно U называют *колмогоровской сложностью*.

Колмогоровская сложность

- Колмогоров и Левин доказали следующую формулу:

$$K(xy) = K(x) + K(y|x) + O(\log n)$$

- Разность $K(y) - K(y|x)$ показывает, насколько знание слова x упрощает описание слова y .
- Понятие условной сложности позволяет ответить на вопрос:
Сколько новой информации в ДНК одного организма по сравнению с ДНК другого?
- Аналогичным образом можно узнать, *какой процент информации был потерян при переводе текста на другой язык*. В этом случае нас интересует отношение:

$$\frac{K(\text{оригинал} | \text{перевод})}{K(\text{оригинал})}$$

Функция K является перечислимой сверху

- Функция K является перечислимой сверху, но не является вычислимой.
- Не существует никакой неограниченной вычислимой нижней оценки для функции K .

- Теорема:

Функция K перечислима сверху, причем выполняется следующее неравенство:

$$|\{y \mid K(y) < n\}| < 2^n \quad \text{при всех } n.$$

Невычислимость Колмогоровской сложности.

Идея доказательства от противного.

Парадоксы

- Не существует такого алгоритма, который по данному слову u определяет его колмогоровскую сложность.

- **Парадокс интересных чисел** связан с утверждением, что все числа интересные:

1 – это *первое* число. **2** – *первое чётное* число. **3** – *первое нечётное простое* число. **4** – интересное число, потому что $4 = 2 \times 2$ и $4 = 2 + 2$.

В какой-то момент мы можем встретить число без интересных свойств. И мы можем назвать это число **первым неинтересным номером** – но это само по себе уже интересное свойство. В итоге неинтересные числа тоже оказываются интересными.

Невычислимость Колмогоровской сложности.

Идея доказательства от противного.

Парадоксы

- *Парадокс Берри* связан с описанием больших чисел:

Чем больше слов мы используем, тем большее число мы можем описать. Рассмотрим число, описываемое следующей фразой:

«Самое маленькое число, которое нельзя описать меньше, чем пятнадцатью словами»

Для описания числа требуется **15, 16** или даже больше слов. Его нельзя описать **12, 13** или **14** словами. Однако, вот в чём проблема: приведённая выше фраза описывает это число при помощи **10** слов. Таким образом, приходим к противоречию.