

С вопросами по всем задачам седьмого ДЗ можно писать Дианкину Игорю.

Задание 1 (1 балл)

Мнемоника: *naïve*

Поиск подстроки в строке алгоритмом наивного поиска.

Инпут читается из файла **in.txt**, записывается в файл **out.txt**

В файле одна строка, в ней строка и паттерн разделенные пробелом.

В случае отсутствия находок писать пустую строку.

Input	ATGATGATG ATG
Output	0 3 6

Задание 2 (2 балла)

Мнемоника: *rabin*

Поиск подстроки в строке алгоритмом Рабина-Карпа.

Инпут читается из файла **in.txt**, записывается в файл **out.txt**

В файле одна строка, в ней строка и паттерн разделенные пробелом.

В случае отсутствия находок писать пустую строку.

Алфавит состоит из букв A T G C.

Input	ATGATGATG ATG
Output	0 3 6

Задание 3 (1 балл)

Мнемоника: *prefsum*

Префикс функция

Инпут читается из файла **in.txt**, записывается в файл **out.txt**

В файле одна строка, в ней слово, в аутпутный файл необходимо записать все значения суффикс-префикс функции через пробел.

Input	abcabcabc
Output	0 0 0 1 2 3 4 5 6

Задание 4 (2 балла)

Мнемоника: *kmp*

Поиск подстроки в строке алгоритмом Кнута-Морриса-Пратта.

Инпут читается из файла **in.txt**, записывается в файл **out.txt**

В файле одна строка, в ней строка и паттерн разделенные пробелом.

В случае отсутствия находок писать пустую строку.

Input	abcabcabc abc
Output	0 3 6

Задание 5 (1 балл)

Мнемоника: *roll_hash*

Инпут читается из файла **in.txt**, записывается в файл **out.txt**

Написать скользящую хэш-функцию (Rolling Hash).

https://ru.wikipedia.org/wiki/Алгоритм_Рабина_—_Карпа

$$\text{hash}(p[1..m]) = \left(\sum_{i=1}^m p[i]x^{m-i} \right) \bmod q,$$

Хэш функция должна быть такой. Здесь $p[i]$ - это ASCII номер символа, в python его можно получить функцией `ord()`. В задании требуется продемонстрировать свойство скольжения хэш функции по данному тексту.

Входные данные: Первая строка входных данных это параметры m , x и q . m - ширина окна, как в рабине-карпе, x и q как в формуле выше. Вторая строка, текст, по подстрокам длины m , которого нужно скользящей вашей хэш-функцией.

Выходные данные: Значения хэш функции для каждого окна.

Примечание: На прямую брать хэш от подстроки можно только на первом шаге, все последующие **должны** быть рассчитаны через сдвиг.

Input	2 2 32 ABCD
Output	4 7 10

Input	2 2 2 ABCD
Output	0 1 0

Input	3 10 1000 ABCD
Output	227 338

Задание 6 (2 балла)

Мнемоника: *bit_search*

Инпут читается из файла **in.txt**, записывается в файл **out.txt**

В данном задании при каждом упоминании хэш-функции будет подразумеваться хэш-функция написанная вами для предыдущего задания, с параметрами $x = 10$ и $q = 64$.

Вам нужно создать 64-битный массив из нулей, как в Фильтре Блума (битовый массив - массив из нулей и единиц).

Вам подается и несколько строк. Нужно проверить какие из строк есть в тексте, взять значения хэш-функции от этих строк, и по значению хэш-функции заменить 0 на 1 в массиве.

Затем полученный массив представить в виде двоичного числа, перевести в десятичную систему счисления и записать в аутпут.

Пример теоретический: У вас есть некий текст, и строка из одного символа "@". Ваш алгоритм находит @ в тексте, применяет хэш-функцию и получает 63 (Описанная хэш-функция от @ должна давать ноль), отправляется по индексу в последнюю ячейку вашего массива и меняет его на единицу. Массив 0000 ... 001 представляя как двоичное число вы получаете 1, переводите в десятичное.

Input	abbans@hhh @
Output	1

В самом задании встречаются только строки из символов "A" и "B".

Input	ABBAB ABB BBBB
Output	32

Input	ABABA BAB BBBB
Output	8796093022208

Доп. Задание 7 (2.5 балла)

Мнемоника: palindrome

Реализовать поиск палиндромов с использованием хэширования. Вам подается строка и требуется найти количество всех подстрок-палиндромов в ней. Подстрока может быть равна самой строке.

Решение должно работать за $O(n \log n)$

Input	AB
-------	----

Output	0
--------	---

Input	ABABA
Output	4

Доп. Задание 8 (3 балла)

Мнемоника: *kmp_binary*

Реализовать Рабина-Карпа для нуклеотидного алфавита с использованием бинарного представления нуклеотидов и бинарных операций (задача, которую давал на подумать Миронов на лекции) для паттерна до длины 16, с возможным несовпадением паттерна и текста на указанное число символов.

Алгоритм должен работать за $O(N + M)$.

Бинарные операции в Python - <https://data-flair.training/blogs/python-bitwise-operators/>

Указания (смотря указания вы лишаете себя части удовольствия в решении задачи):

1. Для перевода кодирования паттерна полезно использовать операцию &
2. Для смещения позиции понадобятся операции побитового сдвига (>>, <<)
3. Для сравнения паттерна и текущего куска текста понадобится операция хог (^)
4. Чтобы подсчитать число несовпавших нуклеотидов нельзя просто проверять в цикле операцией & количество несовпавших битов - это приведет к ассимптотике $O(MN)$. Необходимо использовать битовые трюки, например, этот. (<https://graphics.stanford.edu/~seander/bithacks.html#CountBitsSetTable>). Можете посмотреть вот здесь - https://en.wikipedia.org/wiki/Hamming_weight
5. Так как каждый нуклеотид кодируется последовательностью из двух битов, то строго говоря надо считать число не битов, а пар 01, 10 и 11 в числе. Я специально не пишу какие пары и как брать - предыдущих четырех подсказок более чем достаточно.

Input

На первой строке - паттерн длины до 16.

Во второй строке - строка, в которой надо осуществлять поиск. Ее длина не ограничена.

В третьей строке - сколько несовпадений в паттерне и тексте разрешается.

Output

Начала вхождения всех подстрок, отличающихся от паттерна не более чем на разрешенное число совпадений. Если вхождений нет, то пустая строка.

Input	atgc atgcaatgaatggatgcaattt 0
Output	0 13

Input	atgc atgcaatgaatggatgcaattt 0
Output	0 13

Input	atgc atgcaatgaatggatgcaattt 1
Output	0 5 9 13

Input	atgc atgcaatgaatggatgcaattt 2
--------------	-------------------------------------

Output	0 5 9 13 18
---------------	-------------