

ПЕТРОЗАВОДСКИЙ ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ
ИНСТИТУТ МАТЕМАТИКИ И ИНФОРМАЦИОННЫХ ТЕХНОЛОГИЙ
КАФЕДРА ИНФОРМАТИКИ И МАТЕМАТИЧЕСКОГО ОБЕСПЕЧЕНИЯ

Отчет о прохождении производственной практики

ГЕНЕРАЦИЯ ТЕКСТА БЕЗ ИСПОЛЬЗОВАНИЯ СТАТИСТИКИ
ПРЕФИКСОВ

Выполнил студент 2 курса группы 22207:
Гагарин Валерий Владимирович

Направление подготовки бакалавриата:
09.03.04 Программная инженерия

Место прохождения практики:
Институт математики и информационных технологий

Период прохождения практики:
29.05.23 - 09.06.23

Руководитель:
Богоявленская Ольга Юрьевна, к.т.н, доцент

Оценка:

оценка

Дата:

дата

Содержание

Введение	3
Теория	3
Цель практики	3
Задачи практики	3
Модуль построения матрицы перехода и генерации текста	4
Листинг	4
Методы	6
Инициализация	6
create_prefixes	6
add_prefix	6
make_matrix	6
generate_text_by_matrix	6
Тестирование	7
Заключение	8
Список литературы	9

Введение

Теория

Цепи Маркова — это математический инструмент, который помогает моделировать случайные процессы, где будущее зависит только от текущего состояния, а не от того, как оно сюда попало. В генерации текстов это означает, что мы используем тексты, чтобы определить, как вероятнее всего будет продолжаться предложение или текст.

В качестве основы для генерации текста была выбрана матрица переходов. Этот метод позволяет строить текст, используя вероятности переходов между словами или символами, без необходимости учитывать статистику префиксов.

Цель практики

Реализовать генерацию текста без использования статистики префиксов.

Задачи практики

1. Чтение документации по генерации текстов с помощью цепей Маркова.
2. Реализация генерации текста без использования статистики префиксов.
3. Тестирование разработанного алгоритма.

Модуль построения матрицы перехода и генерации текста

Листинг

Листинг 1: модуль TransitionMatrix, строящий матрицу перехода и генерирующий текст на ее основе

```
import numpy

class TransitionMatrix:
    """класс
    , реализующий генерацию текста с помощью цепи Маркова
    """
    def __init__(self, corpus, length_prefix):
        """ инициализация класса """
        self.corpus = corpus
        self.length_prefix = length_prefix
        self.prefixes = None
        self.matrix = None

    def create_prefixes(self):
        """формирование пар префикс
        - суффикс и разбитого на слова исходного текста
        """
        self.first_prefix = None
        self.prefixes = {}
        for index in range(0, len(self.corpus) - self.length_prefix + 1):
            prefix = tuple(self.corpus[index:index + self.length_prefix])
            if len(self.corpus) <= index + self.length_prefix:
                suffix = None
            else:
                suffix = self.corpus[index + self.length_prefix]
            self.add_prefix(prefix, suffix)
            if self.first_prefix == None:
                self.first_prefix = prefix
        return self.prefixes

    def add_prefix(self, prefix, suffix):
        """сохранение количества суффиксов с определенным префиксом в словарь
```

```

"""
if prefix not in self.prefixes:
    self.prefixes[prefix] = {}
if suffix not in self.prefixes[prefix]:
    self.prefixes[prefix][suffix] = 0
self.prefixes[prefix][suffix] += 1

def make_matrix(self):
    """построение матрицы перехода

    """
    if self.prefixes == None:
        self.create()
    self.matrix = {}
    for prefix, suffixes in self.prefixes.items():
        total_count = sum(suffixes.values())
        self.matrix[prefix] = {suffix: count / total_count for suffix, count :
    return self.matrix

def generate_text_by_matrix(self):
    """генерация текста с помощью матрицы перехода

    """
    if self.matrix == None:
        self.make_matrix()
    current_prefix = self.first_prefix
    result = list(current_prefix)
    while(True):
        suffixes = list(self.matrix[current_prefix].keys())
        probabilities = list(self.matrix[current_prefix].values())
        suffix = numpy.random.choice(suffixes, p=probabilities)
        if suffix == None:
            break
        else:
            result.append(str(suffix))
            current_prefix = tuple(list(current_prefix[1:]) + [suffix])
    return result

```

Методы

Инициализация

На вход принимается разбитый текст на массив слов и длина префикса.

`create_prefixes`

Метод, составляющий пару - префикс: суффикс. Первый префикс, с которого начинается исходный текст и начнется сгенерированный, записываем в переменную. Концом текста является суффикс с значением None.

`add_prefix`

Сохраняем префикс и суффикс в словарь. Увеличиваем число появлений суффикса на 1.

`make_matrix`

Составление матрицы переходов. Проходим по каждому префиксу, получаем суффиксы и количество их появлений, считаем вероятность появления соответствующего суффикса после префикса.

`generate_text_by_matrix`

Генерируем текст на основе матрицы перехода. Начинаем с первого префикса, получаем суффиксы и вероятности, с помощью взвешанного случайного выбора получаем суффикс и строим новый префикс. Генерируем текст пока суффикс не окажется указателем конца текста.

Тестирование

Для проверки работоспособности программы были написаны 16 тестов: 13 позитивных и 3 негативных. Были протестированы следующие случаи:

1. Наличие всех префиксов и суффиксов в матрице перехода.
2. Корректное распределение вероятностей в матрице переходов.
3. Проверка, что сумма вероятностей перехода префикса в суффикс равняется 1 для всех суффиксов.
4. Длина сгенерированного текста больше 0.
5. Ошибка генерация текста для пустого текстового корпуса.
6. Длина префикса должна быть числом.
7. Длина префикса не может быть больше длины текстового корпуса - 1. Все тесты были успешно пройдены. c0.9

```
platform win32 -- Python 3.12.5, pytest-8.3.2, pluggy-1.5.0
rootdir: D:\study\proj\Practice_Markov
plugins: anyio-4.4.0
collected 16 items

tests\test_transitionmatrix.py ..... [100%]

===== 16 passed in 0.33s =====
```

Результат тестирования

Заключение

В ходе практики был реализован алгоритм генерации текста с помощью цепей Маркова с построением матрицы перехода. Код загружен на github и доступен по ссылке [Transition matrix](#).

Список литературы

1. Керниган Б., Пайк Р. *Практика программирования*. 8-е изд. М., СПб., Киев: Издательский дом "Вильямс 2015. 288 с.
2. Краткое введение в цепи Маркова // Habr URL: <https://habr.com/ru/articles/455762/>
3. Генерация текста с помощью цепей Маркова // Блог Саши Беспясова URL: <https://bespoyasov.ru/blog/text-generation-with-markov-chains/>