

## Задание 1. Байесовские рассуждения

Курс: Байесовские методы в машинном обучении, 2016


Начало выполнения задания: 3 сентября  
 Срок сдачи: **17 сентября (суббота), 23:59.**  
 Среда для выполнения задания – PYTHON 2.

## Содержание

|                      |   |
|----------------------|---|
| Вероятностные модели | 1 |
| Вариант 1            | 2 |
| Вариант 2            | 2 |
| Вариант 3            | 3 |
| Оформление задания   | 4 |

## Вероятностные модели посещаемости курса

Рассмотрим модель посещаемости студентами ВУЗа одной лекции по курсу. Пусть аудитория данного курса состоит из студентов профильного факультета, а также студентов других факультетов. Обозначим через  $a$  количество студентов, поступивших на профильный факультет, а через  $b$  – количество студентов других факультетов. Пусть студенты профильного факультета посещают лекцию с некоторой вероятностью  $p_1$ , а студенты остальных факультетов – с вероятностью  $p_2$ . Обозначим через  $c$  количество студентов, посетивших данную лекцию. Тогда случайная величина  $c|a, b$  есть сумма двух случайных величин, распределённых по биномиальному закону  $\text{Bin}(a, p_1)$  и  $\text{Bin}(b, p_2)$  соответственно. Пусть далее на лекции по курсу ведётся запись студентов. При этом каждый студент записывается сам, а также, быть может, записывает своего товарища, которого на лекции на самом деле нет. Пусть студент записывает своего товарища с некоторой вероятностью  $p_3$ . Обозначим через  $d$  общее количество записавшихся на данной лекции. Тогда случайная величина  $d|c$  представляет собой сумму  $c$  и случайной величины, распределённой по биномиальному закону  $\text{Bin}(c, p_3)$ . Для завершения задания вероятностной модели осталось определить априорные вероятности для  $a$  и для  $b$ . Пусть обе эти величины распределены равномерно в своих интервалах  $[a_{min}, a_{max}]$  и  $[b_{min}, b_{max}]$  (дискретное равномерное распределение). Таким образом, мы определили следующую вероятностную модель:




$$\begin{aligned}
 p(a, b, c, d) &= p(d|c)p(c|a, b)p(a)p(b), \\
 d|c &\sim c + \text{Bin}(c, p_3), \\
 c|a, b &\sim \text{Bin}(a, p_1) + \text{Bin}(b, p_2), \\
 a &\sim \text{Unif}[a_{min}, a_{max}], \\
 b &\sim \text{Unif}[b_{min}, b_{max}].
 \end{aligned} \tag{1}$$

Рассмотрим несколько упрощённую версию модели 1. Известно, что биномиальное распределение  $\text{Bin}(n, p)$  при большом количестве испытаний и маленькой вероятности успеха может быть с высокой точностью приближено пуассоновским распределением  $\text{Poiss}(\lambda)$  с  $\lambda = np$ . Известно также, что сумма двух пуассоновских распределений с параметрами  $\lambda_1$  и  $\lambda_2$  есть пуассоновское распределение с параметром  $\lambda_1 + \lambda_2$  (для биномиальных распределений это неверно). Таким образом, мы можем сформулировать вероятностную модель, которая

является приближённой версией модели **1**:

$$\begin{aligned}
 p(a, b, c, d) &= p(d|c)p(c|a, b)p(a)p(b), \\
 d|c &\sim c + \text{Bin}(c, p_3), \\
 c|a, b &\sim \text{Poiss}(ap_1 + bp_2), \\
 a &\sim \text{Unif}[a_{\min}, a_{\max}], \\
 b &\sim \text{Unif}[b_{\min}, b_{\max}].
 \end{aligned} \tag{2}$$

Рассмотрим теперь модель посещения нескольких лекций курса. Будем считать, что посещения отдельных лекций являются независимыми. Тогда:



$$\begin{aligned}
 p(a, b, c_1, \dots, c_N, d_1, \dots, d_N) &= p(a)p(b) \prod_{n=1}^N p(d_n|c_n)p(c_n|a, b), \\
 d_n|c_n &\sim c_n + \text{Bin}(c_n, p_3), \\
 c_n|a, b &\sim \text{Bin}(a, p_1) + \text{Bin}(b, p_2), \\
 a &\sim \text{Unif}[a_{\min}, a_{\max}], \\
 b &\sim \text{Unif}[b_{\min}, b_{\max}].
 \end{aligned} \tag{3}$$

По аналогии с моделью **2** можно сформулировать упрощённую модель для модели **3**:

$$\begin{aligned}
 p(a, b, c_1, \dots, c_N, d_1, \dots, d_N) &= p(a)p(b) \prod_{n=1}^N p(d_n|c_n)p(c_n|a, b), \\
 d_n|c_n &\sim c_n + \text{Bin}(c_n, p_3), \\
 c_n|a, b &\sim \text{Poiss}(ap_1 + bp_2), \\
 a &\sim \text{Unif}[a_{\min}, a_{\max}], \\
 b &\sim \text{Unif}[b_{\min}, b_{\max}].
 \end{aligned} \tag{4}$$

Задание состоит из трёх вариантов.

## Вариант 1

Рассматривается модель **2** с параметрами  $a_{\min} = 75$ ,  $a_{\max} = 90$ ,  $b_{\min} = 500$ ,  $b_{\max} = 600$ ,  $p_1 = 0.1$ ,  $p_2 = 0.01$ ,  $p_3 = 0.3$ . Провести на компьютере следующие исследования:

1. Найти математические ожидания и дисперсии априорных распределений для всех параметров  $a$ ,  $b$ ,  $c$ ,  $d$ .
2. Пронаблюдать, как происходит уточнение прогноза для величины  $c$  по мере прихода новой косвенной информации. Для этого построить графики и найти мат.ожидание и дисперсию для распределений  $p(c)$ ,  $p(c|a)$ ,  $p(c|b)$ ,  $p(c|d)$ ,  $p(c|a, b)$ ,  $p(c|a, b, d)$  при параметрах  $a$ ,  $b$ ,  $d$ , равных мат.ожиданиям своих априорных распределений, округленных до ближайшего целого.
3. Определить, какая из величин  $a$ ,  $b$ ,  $d$  вносит наибольший вклад в уточнение прогноза для величины  $c$  (в смысле дисперсии распределения). Для этого убедиться в том, что  $\mathbb{D}[c|d] < \mathbb{D}[c|b]$  и  $\mathbb{D}[c|d] < \mathbb{D}[c|a]$  для любых допустимых значений  $a$ ,  $b$ ,  $d$ . Найти множество точек  $(a, b)$  таких, что  $\mathbb{D}[c|b] < \mathbb{D}[c|a]$ . Являются ли множества  $\{(a, b) \mid \mathbb{D}[c|b] < \mathbb{D}[c|a]\}$  и  $\{(a, b) \mid \mathbb{D}[c|b] \geq \mathbb{D}[c|a]\}$  линейно разделимыми?
4. Провести временные замеры по оценке всех необходимых распределений  $p(c)$ ,  $p(c|a)$ ,  $p(c|b)$ ,  $p(c|d)$ ,  $p(c|a, b)$ ,  $p(c|a, b, d)$ ,  $p(d)$ .
5. Провести исследования из пп. 1–4 для точной модели **1** и сравнить результаты с аналогичными для модели **2**. Привести пример оценки параметра, для которого проявляется разница между моделью **1** и **2**. Объяснить причины подобного результата.

Взять в качестве диапазона допустимых значений для величины  $c$  интервал  $[0, a_{\max} + b_{\max}]$ , а для величины  $d$  – интервал  $[0, 2(a_{\max} + b_{\max})]$ .

При оценке выполнения задания будет учитываться эффективность программного кода.

## Вариант 2

Рассматривается модель 2 с параметрами  $a_{min} = 75$ ,  $a_{max} = 90$ ,  $b_{min} = 500$ ,  $b_{max} = 600$ ,  $p_1 = 0.1$ ,  $p_2 = 0.01$ ,  $p_3 = 0.3$ . Провести на компьютере следующие исследования:

1. Найти математические ожидания и дисперсии априорных распределений для всех параметров  $a$ ,  $b$ ,  $c$ ,  $d$ .
2. Пронаблюдать, как происходит уточнение прогноза для величины  $b$  по мере прихода новой косвенной информации. Для этого построить графики и найти мат.ожидание и дисперсию для распределений  $p(b)$ ,  $p(b|a)$ ,  $p(b|d)$ ,  $p(b|a, d)$  при параметрах  $a$ ,  $d$ , равных мат.ожиданиям своих априорных распределений, округленных до ближайшего целого.
3. Определить, при каких соотношениях параметров  $p_1$ ,  $p_2$  изменяется относительная важность параметров  $a, b$  для оценки величины  $c$ . Для этого найти множество точек  $\{(p_1, p_2) \mid \mathbb{D}[c|b] < \mathbb{D}[c|a]\}$  при  $a, b$ , равных мат.ожиданиям своих априорных распределений, округленных до ближайшего целого. Являются ли множества  $\{(p_1, p_2) \mid \mathbb{D}[c|b] < \mathbb{D}[c|a]\}$  и  $\{(p_1, p_2) \mid \mathbb{D}[c|b] \geq \mathbb{D}[c|a]\}$  линейно разделимыми?
4. Провести временные замеры по оценке всех необходимых распределений  $p(c)$ ,  $p(c|a)$ ,  $p(c|b)$ ,  $p(b|a)$ ,  $p(b|d)$ ,  $p(b|a, d)$ ,  $p(d)$ .
5. Провести исследования из пп. 1–4 для точной модели 1 и сравнить результаты с аналогичными для модели 2. Привести пример оценки параметра, для которого проявляется разница между моделью 1 и 2. Объяснить причины подобного результата.

Взять в качестве диапазона допустимых значений для величины  $c$  интервал  $[0, a_{max} + b_{max}]$ , а для величины  $d$  – интервал  $[0, 2(a_{max} + b_{max})]$ .

При оценке выполнения задания будет учитываться эффективность программного кода.

## Вариант 3

Рассматривается модель 4 с параметрами  $a_{min} = 75$ ,  $a_{max} = 90$ ,  $b_{min} = 500$ ,  $b_{max} = 600$ ,  $p_1 = 0.1$ ,  $p_2 = 0.01$ ,  $p_3 = 0.3$ ,  $N = 50$ . Провести на компьютере следующие исследования:

1. Найти математические ожидания и дисперсии априорных распределений для всех параметров  $a$ ,  $b$ ,  $c_n$ ,  $d_n$ .
2. Реализовать генератор выборки  $d_1, \dots, d_N$  из модели при заданных значениях параметров  $a, b$ .
3. Пронаблюдать, как происходит уточнение прогноза для величины  $b$  по мере прихода новой косвенной информации. Для этого построить графики и найти мат.ожидание и дисперсию для распределений  $p(b)$ ,  $p(b|d_1), \dots, p(b|d_1, \dots, d_N)$ , где выборка  $d_1, \dots, d_N$  1) сгенерирована из модели при параметрах  $a, b$ , равных мат.ожиданиям своих априорных распределений, округленных до ближайшего целого и 2)  $d_1 = \dots = d_N$ , где  $d_n$  равно мат.ожиданию своего априорного распределения, округленного до ближайшего целого. Провести аналогичный эксперимент, если дополнительно известно значение  $a$ . Сравнить результаты двух экспериментов.
4. Провести временные замеры по оценке всех необходимых распределений  $p(c_n)$ ,  $p(d_n)$ ,  $p(b|d_1, \dots, d_n)$ ,  $p(b|a, d_1, \dots, d_n)$ .
5. Провести исследования из пп. 1–4 для точной модели 3 и сравнить результаты с аналогичными для модели 4.

Взять в качестве диапазона допустимых значений для величины  $c$  интервал  $[0, a_{max} + b_{max}]$ , а для величины  $d$  – интервал  $[0, 2(a_{max} + b_{max})]$ .

При оценке выполнения задания будет учитываться эффективность программного кода.

## Оформление задания

Выполненное задание следует отправить письмом по адресу *bayesml@gmail.com* с заголовком письма

«[БММО15] Задание 1, Фамилия Имя, Номер варианта».

Убедительная просьба присылать выполненное задание только один раз с окончательным вариантом. Также убедительная просьба строго придерживаться заданных ниже прототипов реализуемых функций (для проверки задания используются, в том числе, автоматические процедуры, которые являются чувствительными к неверным прототипам).

Номер варианта вычисляется как  $(s \bmod 3) + 1$ , где  $s$  — сумма кодов букв своей фамилии в кодировке UTF-8. В питоне это выглядит так:

$$\text{sum}([\text{ord}(x) \text{ for } x \text{ in } u'\text{Фамилия}']) \% 3 + 1$$

Присланный вариант задания должен содержать в себе:

- Текстовый файл в формате PDF с указанием ФИО и номера варианта, содержащий описание всех проведённых исследований (вывод необходимых формул, графики, анализ и выводы). Файл должен называться *surname.pdf*, где *surname* — фамилия студента.
- Python модуль со всеми требуемыми функциями в соответствии с прототипами, приведенными ниже. Модуль должен называться *surname.py*, где *surname* — фамилия студента.

## Требования к реализации

Все исходные коды должны располагаться в одном модуле *surname.py*. Распределения должны быть реализованы в виде **отдельных функций**. Прототип функции для оценки распределения  $p(c|a, d)$  показан в таблице 1. Прототипы функций для других распределений выглядят аналогично. Если в распределении переменных до или после  $|$  несколько, то в названии функции они идут в алфавитном порядке. Функция для оценки распределения  $p(b|a, d_1, \dots, d_N)$  для модели 3 имеет название *pb\_ad*, а входной параметр  $d$  является массивом длины  $N$ .

Таблица 1: Прототип функции для оценки распределения  $p(c|a, d)$  для модели 1 и 2

|  |
|--|
| <b><code>p, c = pc_ad(a, d, params, model)</code></b>  |
| <p><b>ВХОД</b><br/> <math>a</math> – значение параметра <math>a</math>;<br/> <math>d</math> – значение параметра <math>d</math>;<br/> <math>params</math> – набор параметров вероятностной модели, словарь с ключами 'amin', 'amax', 'bmin', 'bmax', 'p1', 'p2', 'p3';<br/> <math>model</math> – номер модели;</p> |
| <p><b>ВЫХОД</b><br/> <math>p</math> – распределение вероятности, numpy array длины <math>\text{len}(c)</math>;<br/> <math>c</math> – носитель распределения, numpy array.</p>  |

Таблица 2: Прототип функции для генерации выборки из распределения  $p(d_1, \dots, d_N|a, b)$  для модели 3 и 4

|   |
|---|
| <b><code>d = generate(N, a, b, params, model)</code></b>  |
| <p><b>ВХОД</b><br/> <math>N</math> – количество лекций;<br/> <math>a</math> – значение параметра <math>a</math>;<br/> <math>b</math> – значение параметра <math>b</math>;<br/> <math>params</math> – набор параметров вероятностной модели, словарь с ключами 'amin', 'amax', 'bmin', 'bmax', 'p1', 'p2', 'p3';<br/> <math>model</math> – номер модели;</p> |
| <p><b>ВЫХОД</b><br/> <math>d</math> – значения <math>d_1, \dots, d_N</math>, numpy array длины <math>N</math>.</p>  |