

# Введение в теорию информации. Сжатия тестов.

Дискретный анализ 2012/13

Андрей Калинин, Татьяна Романова

13 апреля 2013 г.

# Раздел

Базовые понятия теории вероятностей

Наивный байесовский классификатор

Теория информации

Сжатие текстов

Модели данных

Адаптивные модели

# Вероятность

Задано пространство элементарных событий (конечное или бесконечное):

$$\Omega = \{\omega_1, \omega_2, \dots\}$$

и функция  $p(\omega_i) \in [0, 1]$ , удовлетворяющая условию нормировки:

$$\sum p(\omega_i) = 1.$$

- ▶ Значения  $p(\omega_i)$  — вероятности элементарных событий  $\omega_i$ .
- ▶ Множества  $A \subset \omega$  — события и их вероятность:

$$P(A) = \sum_{\omega_i \in A} p(\omega_i).$$

## На практике

- ▶ Возможность проведения экспериментов, исходом которых является наступление  $\omega_i$  (событие  $A$  наступает, если наступает  $\omega_i \in A$ )
- ▶ Связь  $\Omega$  с субэлементарным уровнем, например, если событие  $n$ -кратное бросание монеты, то можно выделить связь с однократным бросанием.
- ▶ Возможность проведения серии опытов, в результате чего:

$$\frac{N(A)}{N} \rightarrow P(A) \quad \text{при } N \rightarrow \infty.$$

## Объединение и пересечение событий

$$P(A + B) = P(A) + P(B) - P(AB)$$

Если события не пересекаются, то

$$P(A + B) = P(A) + P(B)$$

## Условная вероятность

- ▶  $P(B|A)$  — вероятность наступления  $B$  при условии наступления в то же время события  $A$ , или условная вероятность.
- ▶ При этом, из всех  $\omega_i \in A$  рассматриваются только  $\omega_i \in B$  и  $P(B|A)$  равнялось бы  $P(AB)$ , если бы  $P(A) = 1$ . Нормируя, получаем:

$$P(B|A) = \frac{P(AB)}{P(A)}.$$

- ▶ Или, формула умножения вероятностей:

$$P(AB) = P(A)P(B|A).$$

## Формула Байеса

Разбиение  $\Omega$  на полную группу несовместимых событий  $A_1, \dots, A_n$  позволяет любое событие  $B$  записать в виде

$$B = BA_1 + \dots + BA_n,$$

откуда  $P(B) = P(BA_1) + \dots + P(BA_n)$ , и получается формула полной вероятности:

$$P(B) = P(B|A_1)P(A_1) + \dots + P(B|A_n)P(A_n).$$

Пусть  $P(A), P(B) > 0$ . Тогда из

$$P(AB) = P(A|B)P(B) = P(B|A)P(A)$$

вытекает

$$P(A|B) = \frac{P(B|A)P(A)}{P(B)}$$

что приводит к формуле Байеса:

$$P(A_j|B) = \frac{P(B|A_j)P(A_j)}{\sum_k P(B|A_k)P(A_k)}.$$

## Примеры

- ▶ Имеются три карточки. На одной — с обеих сторон  $A$ , на другой —  $B$ . На третьей картонке с одной стороны  $A$ , с другой —  $B$ . Одна из картонок выбирается наугад и кладётся на стол. Предположим, на видимой стороне картонки оказывается буква  $A$ . Какова вероятность того, что на другой стороне — тоже  $A$ ?



## Примеры

- ▶ Имеются три карточки. На одной — с обеих сторон  $A$ , на другой —  $B$ . На третьей картонке с одной стороны  $A$ , с другой —  $B$ . Одна из картонок выбирается наугад и кладётся на стол. Предположим, на видимой стороне картонки оказывается буква  $A$ . Какова вероятность того, что на другой стороне — тоже  $A$ ?
- ▶ Некоторая болезнь имеется у 1 человека на 100. Имеется тест, определяющий наличие болезни с 95%-ой точностью (т.е., в 5% случаев срабатывания теста его результат неверен). Допустим, для тестирования случайно отбирают людей и тест «сработал» на каком-то человеке. Какова вероятность того, что он болен этой болезнью?

## Парадокс Монти Холла

- ▶ Представьте, что вы стали участником игры, в которой вам нужно выбрать одну из трех дверей. За одной из дверей находится автомобиль, за двумя другими дверями — козы. Вы выбираете одну из дверей, например, номер 1, после этого ведущий, который знает, где находится автомобиль, а где — козы, открывает одну из оставшихся дверей, например, номер 3, за которой находится коза. После этого он спрашивает вас, не желаете ли вы изменить свой выбор и выбрать дверь номер 2. Увеличатся ли ваши шансы выиграть автомобиль, если вы примете предложение ведущего и измените свой выбор?

# Независимость

События  $A$  и  $B$  называют независимыми, если  $P(B|A) = P(B)$ , т.е.

$$P(AB) = P(A)P(B).$$

# Случайные величины

- ▶ Числовая функция  $X(\omega)$ , заданная на  $\Omega$  представляет собой случайную величину (например, 1 при выпадении герба, 0 — решки).
- ▶ Среднее значение  $m_x = E(X)$ ,

$$E(X) = \sum_{\omega \in \Omega} X(\omega)P(\omega),$$

называют математическим ожиданием  $X(\omega)$ .

- ▶ Математическое ожидание линейно:

$$E(\alpha X + \beta Y) = \alpha E(X) + \beta E(Y).$$

## Парадокс ожидания серии

- ▶ Какая комбинация, 00 или 01, появится раньше в случайной «01»-последовательности?
- ▶ Очевидно, равновероятно, т.к. после первого нуля появление 0 или 1 — вероятность  $1/2$ .

## Парадокс ожидания серии

- ▶ Какая комбинация, 00 или 01, появится раньше в случайной «01»-последовательности?
- ▶ Очевидно, равновероятно, т.к. после первого нуля появление 0 или 1 — вероятность  $1/2$ .
- ▶ Однако, число шагов (среднее время ожидания)  $m_{00}$  и  $m_{01}$  — не одинаково:
  - ▶ Пусть  $m_0$  — среднее число шагов до 01 при условии, что первая цифра последовательности была 0, а  $m_1$  — то же самое, но для 1. Тогда:

$$m_0 = 1 + \frac{1}{2} + \frac{1}{2}m_0, \quad m_1 = 1 + \frac{1}{2}m_0 + \frac{1}{2}m_1,$$

откуда  $m_0 = 3$ ,  $m_1 = 5$  и  $m_{01} = .5(m_0 + m_1) = 4$ .

- ▶ Если же  $m_0^*$  и  $m_1^*$  аналоги  $m_0$  и  $m_1$  в для 00, то:

$$m_0^* = 1 + \frac{1}{2} + \frac{1}{2}m_1^*, \quad m_1^* = 1 + \frac{1}{2}m_0^* + \frac{1}{2}m_1^*,$$

и в конечном итоге это даёт  $m_{00} = .5(m_0^* + m_1^*) = 6$ .

# Петербургский парадокс

- ▶ Если герб при неоднократном бросании монеты выпадает первый раз в  $n$ -й попытке, участнику игры выплачивается  $2^n$  рублей.
- ▶ Математическое ожидание выигрыша,

$$2 \cdot \frac{1}{2} + 4 \cdot \frac{1}{4} + \dots + 2^n \cdot \frac{1}{2^n} + \dots = 1 + 1 + \dots ,$$

бесконечно.

- ▶ Сколько можно заплатить за участие в игре?

# Петербургский парадокс

- ▶ Если герб при неоднократном бросании монеты выпадает первый раз в  $n$ -й попытке, участнику игры выплачивается  $2^n$  рублей.
- ▶ Математическое ожидание выигрыша,

$$2 \cdot \frac{1}{2} + 4 \cdot \frac{1}{4} + \dots + 2^n \cdot \frac{1}{2^n} + \dots = 1 + 1 + \dots,$$

бесконечно.

- ▶ Сколько можно заплатить за участие в игре?
- ▶ Кажется, что сколько угодно — казино проиграет.
- ▶ Но это «в среднем», а единичная игра скорее не принесёт большого выигрыша и платить большие деньги не имеет смысла.



# Раздел

Базовые понятия теории вероятностей

Наивный байесовский классификатор

Теория информации

Сжатие текстов

Модели данных

Адаптивные модели

# Задача классификации

- ▶  $C$  — некоторый класс, к которому можно отнести наблюдаемый объект. Любой объект относится либо к  $C$ , либо к  $\neg C$ .
- ▶  $F_1, \dots, F_n$  — факторы, некоторые наблюдаемые характеристики объекта.
- ▶ Задача — при неких полученных значениях факторов определить принадлежность события к классу, т.е. вычислить:

$$P(C|F_1, \dots, F_n).$$

- ▶ Количество факторов может быть велико.
- ▶ Примеры факторов: слова в тексте, результаты измерений, телеметрические данные и т.п.

## Модель

- ▶ Из формулы условной вероятности:

$$P(C|F_1, \dots, F_n) = \frac{P(C)P(F_1, \dots, F_n|C)}{P(F_1, \dots, F_n)}$$

- ▶ Для оценки вероятности принадлежности к классу  $C$  интересно только  $P(C)P(F_1, \dots, F_n|C)$ , т.к.  $P(F_1, \dots, F_n)$  не зависит от класса.
- ▶ При этом  $P(C)P(F_1, \dots, F_n|C) = P(C, F_1, \dots, F_n)$ .
- ▶ Тогда:

$$\begin{aligned} P(C, F_1, \dots, F_n) &= P(C)P(F_1, \dots, F_n|C) = \\ &= P(C)P(F_1, C)P(F_2, \dots, F_n, |C, F_1) = \\ &= P(C)P(F_1, C)P(F_2|C, F_1) \times \\ &\quad \times P(F_3, \dots, F_n, |C, F_1, F_2) = \\ &= P(C)P(F_1, C)P(F_2|C, F_1)P(F_3|C, F_1, F_2) \times \dots \\ &\quad \times P(F_n|C, F_1, F_2, F_3, \dots, F_{n-1}). \end{aligned}$$

## Наивная модель

- ▶ Наивное предположение: предполагаем независимость факторов друг от друга.
- ▶ Т.к. факторы независимы, то для  $i \neq j$ :

$$P(F_i|C, F_j) = P(F_i|C)$$

- ▶ Тогда:

$$\begin{aligned} P(C, F_1, \dots, F_n) &= P(C)P(F_1|C)P(F_2|C)P(F_3|C) \cdots P(F_n|C) \\ &= P(C) \prod_{i=1}^n P(F_i|C). \end{aligned}$$

- ▶ И вся модель:

$$P(C|F_1, \dots, F_n) = \frac{1}{Z} P(C) \prod_{i=1}^n P(F_i|C)$$

где  $Z$  зависит только от  $F_1, \dots, F_n$ , т.е. константа при заданных значениях факторов.

# Классификация

- ▶ Предварительно нужно оценить вероятности  $P(F_i|C)$ .
- ▶ После чего:

$$\text{classify}(f_1, \dots, f_n) = \arg \max_c P(C = c) \prod_{i=1}^n P(F_i = f_i | C = c).$$

# Классификация текстовых документов

- ▶ Характеристика — наличие слова в тексте, т.е. нужно предварительно оценить

$$P(w_i|C).$$

- ▶ Предполагаем, что слова никак не связаны друг с другом, их вес не зависит от длины документа и т.п. Тогда:

$$P(D|C) = \prod_i P(w_i|C)$$

- ▶ Для условной вероятности:

$$P(C|D) = \frac{P(C)}{P(D)}P(D|C).$$

## Два класса

- ▶ Допустим, есть только два класса,  $S$  и  $\neg S$ .
- ▶ Тогда можно оценить принадлежность документа к каждому из классов:

$$P(D|S) = \prod_i P(w_i|S)$$

$$P(D|\neg S) = \prod_i P(w_i|\neg S).$$

- ▶ Или:

$$P(S|D) = \frac{P(S)}{P(D)} \prod_i P(w_i|S)$$

$$P(\neg S|D) = \frac{P(\neg S)}{P(D)} \prod_i P(w_i|\neg S)$$

- ▶ Взав отношение двух величин:

$$\frac{P(S|D)}{P(\neg S|D)} = \frac{P(S)}{P(\neg S)} \prod_i \frac{P(w_i|S)}{P(w_i|\neg S)}$$

- ▶ Для удобства расчётов можно перейти к логарифмам:

$$\ln \frac{P(S|D)}{P(\neg S|D)} = \ln \frac{P(S)}{P(\neg S)} + \sum_i \ln \frac{P(w_i|S)}{P(w_i|\neg S)}$$

- ▶ Документ относится к категории  $S$  если  $P(S|D) > P(\neg S|D)$ , т.е.

$$\ln \frac{P(S|D)}{P(\neg S|D)} > 0.$$



# Раздел

Базовые понятия теории вероятностей

Наивный байесовский классификатор

Теория информации

Сжатие текстов

Модели данных

Адаптивные модели

## Интуитивное понятие информации

- ▶ Сколько информации содержится в строке текста? На сколько ее можно сжать без потери смысла сообщения?
- ▶ Есть 10 букв и алфавит из 33 символов, сколько различных строк можно представить?
- ▶ Допустим, мы можем передать  $\Sigma^N$  различных сообщений. Только  $n$  из них будут иметь смысл. для того, чтобы указать, какое из  $n$  сообщений мы передаем, достаточно  $I = \log_2 n$  бит.
- ▶ С удвоением строки, количество возможных сообщений растет квадратично.
- ▶ Самое лучшее соотношение количества информации к длине сообщения у случайных строк. Для передачи  $2^N$  случайных равновероятных сообщения требуется ровно  $N$  бит, меньше — невозможно, больше — избыточно.

# Энтропия

- ▶ Пусть у нас есть язык, алфавит которого состоит из  $k$  символов:  $a_1, a_2, \dots, a_k$ , и для каждого символа известна вероятность его появления в тексте  $p_1, p_2, \dots, p_k$ .
- ▶ Мы хотим определить количество информации в сообщении из данного языка.
- ▶ Если сообщение имеет длину  $N$ , то символов  $a_1$  в нем будет примерно  $Np_1$ ,  $a_2$  —  $Np_2$  и т. п. Посчитаем, сколько различных сообщений такого вида (с таким распределением вероятностей) может быть:

$$\frac{N!}{(Np_1)!(Np_2)! \dots (Np_k)!}$$

- ▶ Чтобы узнать, сколько бит нужно, для передачи одного из таких сообщений, нужно взять логарифм по основанию 2. Это же число можно назвать средним количеством информации в сообщении или энтропией:

$$I(s) = H(s) = N \sum_{i=1}^k -p_i * \log_2(p_i)$$

# Энтропия

- ▶ Чтобы узнать, сколько бит нужно, для передачи одного из таких сообщений, нужно взять логарифм по основанию 2. Это же число можно назвать средним количеством информации в сообщении или энтропией:

$$I(s) = H(s) = N \sum_{i=1}^k -p_i * \log_2(p_i)$$

- ▶ Часто энтропией называют среднее количество информации на символ. Информационная двоичная энтропия для независимых случайных событий  $x$  с  $k$  возможными состояниями рассчитывается по формуле:

$$H(x) = - \sum_{i=1}^k p_i * \log_2 p_i$$

- ▶ Условная энтропия  $n$ -го порядка — энтропия для алфавита, в котором известны вероятности появления буквы после  $n$  других. Условная энтропия всегда меньше безусловно, например, для русского языка

# Раздел

Базовые понятия теории вероятностей

Наивный байесовский классификатор

Теория информации

**Сжатие текстов**

Модели данных

Адаптивные модели

# Введение в проблему

- ▶ Компрессия текстов использовалась до компьютеров: азбука Морзе, коды Брайля.
- ▶ Нужна для уменьшения объёмов хранения и передачи данных.
- ▶ Часть более общей задачи компрессии данных: отличие в возможности точного восстановления информации (для некоторых данных это не всегда возможно и не всегда требуется).

# Развитие

1950-е коды Хаффмана.

1970-е Зив-Лемпель (словарные методы) и арифметическое кодирование (символьные методы): адаптивное сжатие.

1980-е PPM (prediction by partial matching, предсказание по частичному совпадению).

1990-е преобразование Барроуза-Уиллера, сжатие блоков данных; улучшение вычислительных характеристик алгоритмов.

- ▶ На текущий момент: два бита на символ для среднего английского текста.
- ▶ Предположительно один бит на символ недостижим.

# Классификация методов компрессии текстов

- ▶ Символьные (статистические): кодирование одного символа как можно меньшей последовательностью бит.
  - ▶ Коды Хаффмана.
  - ▶ Арифметическое кодирование.

Основное отличие между методами в том, как вычисляются вероятности появления следующих символов — построение модели текста.

- ▶ Словарные: несколько часто встречающихся символов кодируются меньшей последовательностью бит, указывающих на соответствующий вход в словарь. В основном это варианты алгоритма Зива-Лемпеля.



# Раздел

Базовые понятия теории вероятностей

Наивный байесовский классификатор

Теория информации

**Сжатие текстов**

**Модели данных**

Адаптивные модели

# Модель данных

- ▶ Задача модели — предсказывать следующие символы в потоке данных.
- ▶ Кодер и декодер используют одинаковую модель для упаковки и распаковки текста.



# Информация

- ▶ Количество бит для символа  $s$  — информация, в нём содержащаяся.  $I(s) = -\log P(s)$ .
- ▶ Средняя информация по всему алфавиту:

$$H = \sum_s P(s)I(s) = \sum_s -P(s) \log P(s)$$

- ▶ Энтропия — нижний предел для алгоритмов компрессии данных, измеряемый в битах на символ.
- ▶ Коды Хаффмана часто оказываются близкими к этому пределу, однако в некоторых ситуациях очень неэффективны (в случаях  $P(s) \rightarrow 1$  и  $I(s) \rightarrow 0$ ).
- ▶ Арифметический кодер свободен от этих недостатков, но более медленный.


## Использование моделей

- ▶ Кодер и декодер должны использовать одну и ту же модель.
- ▶ Кодер не может «подсматривать» вперёд для оценки вероятностей (потому что этого не может сделать декодер).
- ▶ Символы с  $P(s) = 0$  не могут быть закодированы ( $I(s) = \infty$ ).
- ▶ Символы с  $P(s) = 1$  не нуждаются в сжатии ( $I(s) = 0$ ).
- ▶ Лучшая модель та, которая предсказывает настоящие символы из потока с максимальной вероятностью.

## Контекстно ограниченная модель

- ▶ Вероятность появления английской буквы  $u$  в английском тексте 2%, т.е.  $I(u) \simeq 5,6$  битов.
- ▶ Однако, после появления буквы  $q$  вероятность того, что следующий символ будет  $u$  95%, т.е.  $P(u|q) \simeq .95$  и  $I(u|q) \simeq 0,074$  бит. (*quality, quite, quiet, ...*).
- ▶ В этих случаях кодирование исключений будет требовать больше бит (слова *Iraq, Qantas*), но в среднем объём сжатых текстов уменьшится.
- ▶ Использование предыдущих  $m$  символов для предсказания — контекстно ограниченная модель порядка  $m$ .

## Модель конечного автомата



- ▶ В состояниях содержится информация о распределении символов.
- ▶ Такая модель непредставима контекстно ограниченной моделью (отслеживает чётное или нечётное количество символов).

# Вероятностное распределение символов

- ▶ Кодер должен закодировать обрабатываемый символ и только после этого изменить распределение.
- ▶ Декодер раскодирует символ в соответствии с текущим распределением, после чего делает аналогичное изменение.
- ▶ Предполагается безошибочная передача данных между кодером и декодером.
- ▶ Если известна формальная грамматика текста (C, Java), то её можно использовать для моделирования.

# Раздел

Базовые понятия теории вероятностей

Наивный байесовский классификатор

Теория информации

**Сжатие текстов**

Модели данных

**Адаптивные модели**



# Оценка вероятностей

- ▶ Статическое моделирование: во время разработки модели назначается распределение и используется для всех входных текстов.
- ▶ Полустатическое моделирование: создание распределения вероятностей на основе входного файла. Требуется два прохода по файлу (сбор статистики и сжатие) а так же явная передача данных модели от кодера к декодеру.
- ▶ Адаптивное моделирование: изменение распределения вероятностей во время сжатия входных данных.

## Пример

*"I never heerd a silful old married feller of twenty years' standing pipe "my wife" in a more used note than 'a did," said Jacob Smallbury. It migh*

Для модели нулевого порядка:

- ▶  $P(t) = 49,983/768,078 = 6.5\%$ .
- ▶  $P(e) = 9.4\%$ .
- ▶  $P(x) = 0.11\%$ .

Так как следующая буква t, декодер закодирует её  $-\log 0.065 = 3.94$  битами.

## Символы с нулевой частотой

Необходимо избегать ситуаций, при которых некоторые символы оцениваются с нулевой вероятностью.

- ▶ В примере ни разу не встретилась  $Z$ , так что простая оценка  $P(Z) = 0$  и эта буква не сможет быть закодирована. Строка `MighZ` довольно необычна, но не невероятна.

## Символы с нулевой частотой

Необходимо избегать ситуаций, при которых некоторые символы оцениваются с нулевой вероятностью.

- ▶ В примере ни разу не встретилась  $Z$ , так что простая оценка  $P(Z) = 0$  и эта буква не сможет быть закодирована. Строка MighZ довольно необычна, но не невероятна.
- ▶ Один из способов решения проблемы — назначение всем символам, которые до сих пор не встречались, суммарной единичной частоты:
  1. В примере 82 символа встретились, 46 ASCII-символов не встречались ни разу. Тем самым, они суммарно должны разделить между собой  $1/768,079$ .
  2. Т.е.,  $P(Z) = 1/(46 \times 768,079) = 1/35,331,634$ , что соответствует 25.07 битам.

## Символы с нулевой частотой

Необходимо избегать ситуаций, при которых некоторые символы оцениваются с нулевой вероятностью.

- ▶ В примере ни разу не встретилась  $Z$ , так что простая оценка  $P(Z) = 0$  и эта буква не сможет быть закодирована. Строка MighZ довольно необычна, но не невероятна.
- ▶ Один из способов решения проблемы — назначение всем символам, которые до сих пор не встречались, суммарной единичной частоты:
  1. В примере 82 символа встретились, 46 ASCII-символов не встречались ни разу. Тем самым, они суммарно должны разделить между собой  $1/768,079$ .
  2. Т.е.,  $P(Z) = 1/(46 \times 768,079) = 1/35,331,634$ , что соответствует 25.07 битам.
- ▶ Другой способ — назначение всем символам изначальной единичной частоты. Тогда  $P(Z) = 1/768,206$ , соответствует 19.6 битам.

## Символы с нулевой частотой

Необходимо избегать ситуаций, при которых некоторые символы оцениваются с нулевой вероятностью.

- ▶ В примере ни разу не встретилась  $Z$ , так что простая оценка  $P(Z) = 0$  и эта буква не сможет быть закодирована. Строка MighZ довольно необычна, но не невероятна.
- ▶ Один из способов решения проблемы — назначение всем символам, которые до сих пор не встречались, суммарной единичной частоты:
  1. В примере 82 символа встретились, 46 ASCII-символов не встречались ни разу. Тем самым, они суммарно должны разделить между собой  $1/768,079$ .
  2. Т.е.,  $P(Z) = 1/(46 \times 768,079) = 1/35,331,634$ , что соответствует 25.07 битам.
- ▶ Другой способ — назначение всем символам изначальной единичной частоты. Тогда  $P(Z) = 1/768,206$ , соответствует 19.6 битам.
- ▶ Выбор способа борьбы с проблемой существенно влияет на эффективность сжатия коротких текстов и сглаживается для больших.

## Адаптивные модели высоких порядков

*"I never heard a silful old married feller of twenty years' standing pipe "my wife" in a more used note than 'a did," said Jacob Smallbury. It migh*

► Модель первого порядка:

1.  $c[h] = 37,525$ ,  $c[t|h] = 1,133$ .
2. Опуская проблему символов с нулевой частотой,  $P(t|h) = 1,133/37,525 = 3.02\%$ ,
3. Будет закодировано 5.05 битами (хуже, чем модель нулевого порядка для этого случая, т.к. за  $h$  чаще следует  $e$ ).

► Модель второго порядка:

1.  $c[gh] = 1,754$ ,  $c[t|gh] = 1,129$ .
2.  $P(t|gh) = 64.4\%$ .
3. Будет использован код длиной 0.636 бит.

# Изменение структуры модели

- ▶ В адаптивной модели может меняться не только распределение частот, но и структура модели.
- ▶ Например, в модели конечного автомата могут добавляться новые состояния и генерироваться новые переходы в эти состояния.
- ▶ Обычно структура меняется в тех местах модели, которые часто используются.



# Выводы

- ▶ Адаптивная модель позволяет добиться хорошего качества сжатия.
- ▶ Однако, с её использованием нельзя получить доступ к случайному месту внутри сжатого файла: нужно пройти весь путь от начала сжатого файла до этого места, чтобы получить нужную модель.