

Рис. 1

$$+ b(1 - 3e^{-2b} + 2e^{-3b})f_{ab} + (1 - e^{-b})^3 f_b. \quad (31)$$

Из приведённых на рис. 1 графиков зависимости eff_a , eff_b , eff от b следует, что эффективность МНК-оценки параметра a достаточно высока. При $-0,9 < b < 1,5$ эффективность не менее 0,9. Эффективность параметра b несколько ниже, чем эффективность параметра a . Так, значения 0,9 она достигает при $0,6 < b < 1,7$, а при увеличении или уменьшении b эффективность МНК-оценки параметра b , как и параметра a , убывает. Эффективность МНК-оценки тренда достигает своего наибольшего значения 0,91 при $b = 1,4$, а с уменьшением или увеличением b она убывает.

ЛИТЕРАТУРА

1. Кокс Д., Льюис П. Статистический анализ последовательностей событий. М.: Мир, 1969. 312 с.
2. Тривоженко Б.Е. Асимптотические свойства моментов наступления событий нестационарного пуассоновского потока // Математическое моделирование. Кибернетика. Информатика. Томск: Изд-во Том. ун-та, 1999. С. 140-150.
3. Свешников А.Г., Тихонов А.Н. Теория функций комплексной переменной. М.: Наука, 1979. 319 с.

Статья представлена кафедрой теории вероятностей и математической статистики факультета прикладной математики и кибернетики Томского государственного университета, поступила в научную редакцию 14 марта 2000 г.

УДК 519.24

С.С. Тарима

СТАТИСТИЧЕСКОЕ ОЦЕНИВАНИЕ ВЕРОЯТНОСТЕЙ С ПРИВЛЕЧЕНИЕМ ДОПОЛНИТЕЛЬНОЙ ИНФОРМАЦИИ

Рассматривается способ учета дополнительной информации о вероятностях одних событий для улучшения эмпирических оценок вероятностей других. Приведен пример такого учета.

1. Пусть X_1, \dots, X_n – последовательность независимых одинаково распределенных случайных величин, принимающих значения из измеримого пространства (X, B) с неизвестным распределением P . Рассмотрим события A, B_1, \dots, B_s принадлежащие σ -алгебре B . Предположим, что $P(B_i) = b_i$, где b_i известны ($i=1, \dots, s$). Рассмотрим задачу статистического оценивания $P(A)$ с учетом данной информации. Результаты наблюдений представим в виде протокола:

	A	B_1	$B_1 \dots$	B_s
X_1	$I_A(X_1)$	$I_{B_1}(X_1)$	$I_{B_1}(X_1) \dots$	$I_{B_s}(X_1)$
X_2	$I_A(X_2)$	$I_{B_1}(X_2)$	$I_{B_1}(X_2) \dots$	$I_{B_s}(X_2)$
...
X_i	$I_A(X_i)$	$I_{B_1}(X_i)$	$I_{B_1}(X_i) \dots$	$I_{B_s}(X_i)$
...
X_n	$I_A(X_n)$	$I_{B_1}(X_n)$	$I_{B_1}(X_n) \dots$	$I_{B_s}(X_n)$

В клетках протокола наблюдений $I_D(X_i)$ – индикатор некоторого события D из σ -алгебры B .

Рассмотрим события $\Lambda_j = U_1 \cap U_2 \cap \dots \cap U_s$, где U_i либо B_i , либо его дополнение, $i=1, \dots, s$. Их совокупность, с возможным количеством до 2^s событий, является разбиением пространства X . В этом случае имеют место равенства

$$\sum_{\Lambda_j \in B_j} P(\Lambda_j) = b_j, \quad j = 1, \dots, s. \quad (1)$$

2. Для случая известных значений $P(\Lambda_j)$ в [3] была предложена оценка

$$P_n^*(A) = \sum_{i=1}^{2^s} P(\Lambda_i) \frac{P_n(A \cap \Lambda_i)}{P_n(\Lambda_i)}, \quad P_n(\Lambda_i) > 0, \quad (2)$$

где

$$P_n(A) = \frac{1}{n} \sum_{i=1}^n I_A(X_i).$$

В протоколе наблюдений часто реализуются не все события Λ_i . Предположим, что реализовалось только k из 2^s событий Λ_i , для которых $P_n(\Lambda_i) > 0$. Остальные события в формуле (2) при рассмотрении отношения дают неопределенность типа 0/0 (если $P_n(\Lambda_i) = 0$, то и $P_n(A \cap \Lambda_i) = 0$). Аналогично, из событий B_1, \dots, B_s также реализуются не все, а только часть, допустим $m \leq k$. Для этой ситуации рассмотрим следующую оценку

$$P_n^{**}(A) = \frac{\sum_{i=1, P_n(\Lambda_i) > 0}^{2^s} P(\Lambda_i) \frac{P_n(A \cap \Lambda_i)}{P_n(\Lambda_i)}}{\sum_{i=1, P_n(\Lambda_i) > 0}^{2^s} P(\Lambda_i)}. \quad (3)$$

Суммирование ведется только по тем индексам, для которых эмпирическая оценка события Λ_i не равна нулю. Эта оценка в отличие от (2) определена при любых $P_n(\Lambda_i)$.

3. В нашем случае значения $P(\Lambda_i)$ неизвестны, но удовлетворяют условиям (1). Осталось оценить k вероятностей $P(\Lambda_i)$. Если оценивать $P(\Lambda_i)$ распределением $P_n(\Lambda_i)$, то из (3) мы получаем $P_n^{**}(A) = P_n(A)$.

Найдем проекцию [ближайшую в смысле информационного расхождения (4)] $P_n^{**}(A)$ в класс, удовлетворя-

ющий условию (1). Информационное расхождение между $\{P(\Lambda_i)\}$ и $\{P_n(\Lambda_i)\}$ будет следующим:

$$d_H(P(\Lambda), P_n(\Lambda)) = \sum_{i=1, P_n(\Lambda_i) > 0}^2 P(\Lambda_i) \ln \frac{P_n(\Lambda_i)}{P(\Lambda_i)}. \quad (4)$$

Заметим, что суммирование ведется только по положительным $P_n(\Lambda_i)$ вследствие необходимости абсолютной непрерывности меры P по отношению к мере P_n . Оценим $P(\Lambda_i)$ из условия минимума информационного расхождения при условии (1) и условии нормировки, которое в нашем случае определяется как:

$$\sum_{i=1, P_n(\Lambda_i) > 0}^2 P(\Lambda_i) = 1. \quad (5)$$

Нахождение $P(A)$ свелось к задаче нелинейного программирования. Пусть решение поставленной задачи нелинейного программирования будет $\{P^*(\Lambda_i); i=1, \dots, 2^2\}$; подставив это решение в (3), получим

$$P_n^{***}(A) = \sum_{i=1, P_n(\Lambda_i) > 0}^2 P^*(\Lambda_i) \frac{P_n(A\Lambda_i)}{P_n(\Lambda_i)}. \quad (6)$$

4. Рассмотрим случай, где решение задачи нелинейного программирования находится в явном виде. При $P(B_j) = b_j$, где $j=1, 2$, получим:

$$\begin{aligned} P(\Lambda_1) &= P(B_1 \cap B_2); \quad P(\Lambda_2) = P(B_1 \cap (\Omega \setminus B_2)); \\ P(\Lambda_3) &= P((\Omega \setminus B_1) \cap B_2); \quad P(\Lambda_4) = P((\Omega \setminus B_1) \cap (\Omega \setminus B_2)); \\ P(A) &= P(B_1 B_2) = ?. \end{aligned}$$

Если наблюдения распределились по всем четырем множествам, то на вероятности $P(\Lambda_i)$ наложены три ограничения:

$$\begin{aligned} P(\Lambda_1) + P(\Lambda_2) &= b_1; \quad P(\Lambda_1) + P(\Lambda_3) = b_2; \\ P(\Lambda_1) + P(\Lambda_2) + P(\Lambda_3) + P(\Lambda_4) &= 1. \end{aligned}$$

Определив одну из вероятностей $P(\Lambda_i)$ из наложенных ограничений, можно найти остальные. Оценим $P(\Lambda_1)$ из условия минимума информационного расхождения, которое в рассматриваемом случае примет вид

$$\begin{aligned} d_H(P(\Lambda_i), P_n(\Lambda_i)) &= \sum_{i=1}^4 P(\Lambda_i) \ln \frac{P_n(\Lambda_i)}{P(\Lambda_i)} = \\ &= P(\Lambda_1) \ln \frac{P_n(\Lambda_1)}{P(\Lambda_1)} + (b_2 - P(\Lambda_1)) \times \\ &\times \ln \frac{P_n(\Lambda_2)}{b_2 - P(\Lambda_1)} + (b_1 - P(\Lambda_1)) \times \\ &\times \ln \frac{P_n(\Lambda_3)}{b_1 - P(\Lambda_1)} + (1 - b_2 - b_1 + P(\Lambda_1)) \times \\ &\times \ln \frac{P_n(\Lambda_4)}{1 - b_2 - b_1 + P(\Lambda_1)}. \end{aligned} \quad (7)$$

Минимизация (7) по $P(\Lambda_1)$ приводит к уравнению

$$\left(1 - \frac{P_n(\Lambda_1)P_n(\Lambda_4)}{P_n(\Lambda_2)P_n(\Lambda_3)}\right) P^2(\Lambda_1) +$$

$$\begin{aligned} &+ \left(1 - b_1 - b_2 + b_1 \frac{P_n(\Lambda_1)P_n(\Lambda_4)}{P_n(\Lambda_2)P_n(\Lambda_3)} + \right. \\ &\left. + b_2 \frac{P_n(\Lambda_1)P_n(\Lambda_4)}{P_n(\Lambda_2)P_n(\Lambda_3)}\right) \times \\ &\times P(\Lambda_1) - b_1 b_2 \frac{P_n(\Lambda_1)P_n(\Lambda_4)}{P_n(\Lambda_2)P_n(\Lambda_3)} = 0. \end{aligned} \quad (8)$$

Решение уравнения (8) следующее:

$$\begin{aligned} P_n^*(\Lambda_1) &= \left(\frac{b_1 + b_2}{2} + \frac{t}{2(1-t)}\right) \pm \\ &\pm \sqrt{\left(\frac{b_1 + b_2}{2} + \frac{t}{2(1-t)}\right)^2 - \frac{b_1 b_2}{(1-t)}}, \end{aligned} \quad (9)$$

где $t = \frac{P_n(\Lambda_2) \cdot P_n(\Lambda_3)}{P_n(\Lambda_1) \cdot P_n(\Lambda_4)}$. Это решение и есть оценка

$P(\Lambda_1)$, которая однозначно определяет $P(\Lambda_2)$, $P(\Lambda_3)$, $P(\Lambda_4)$ из вышеупомянутых наложенных ограничений.

В выражении (9), когда $t < 1$, используем «минус», а когда $t > 1$ – «плюс». При $t = 1$ (случай независимости событий B_1 и B_2 между собой) выражение (9) берем равным $b_1 \times b_2$. График зависимости $P_n^*(\Lambda_1)$ от t будет следующий:

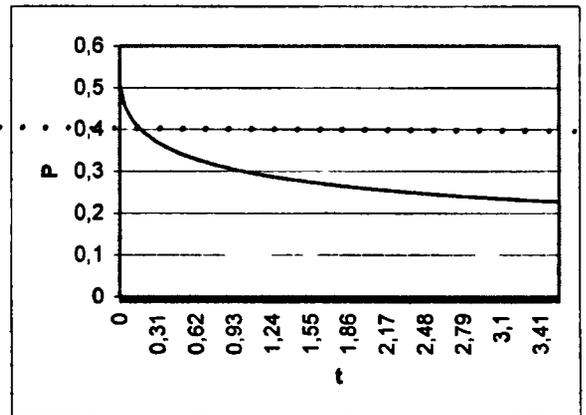


График приведен для $P(B_1) = 0,5$ и $P(B_2) = 0,6$

Оценка вероятности $P(B_1 B_2)$ изменяется в границах от $\max\{0; b_1 + b_2 - 1\}$ до $\min\{b_1; b_2\}$, а эмпирическая оценка (по комплектам наблюдений) искомой вероятности изменяется от 0 до 1. Остальные оценки вероятностей определяются из условия нормировки и двух дополнительных ограничений.

Если наблюдения не попали в одно из четырех множеств, то наши три ограничения однозначно фиксируют три оставшихся $P(\Lambda_i)$.

ЛИТЕРАТУРА

1. Тарима С.С. О свойствах эмпирического распределения, модифицированного с учетом знания вероятностей // Мат. моделирование и теория вероятностей / Под ред. И.А. Александрова, Томск: Пеленг, 1998. С. 257.
2. Кульбак С. Теория информации и статистики. М.: Наука, 1967. 408 с..
3. Дмитриев Ю.Г., Устинов Ю.К. Статистическое оценивание распределений вероятностей с использованием дополнительной информации. Томск: Изд-во ТГУ, 1988.

Статья представлена кафедрой теоретической кибернетики факультета прикладной математики и кибернетики Томского государственного университета, поступила в научную редакцию 14 февраля 2000 г.