

ББК
22.17
М 197



У ч е б н о е п о с о б и е

С. В. Малов И. Ю. Малова

БАЗОВЫЕ МОДЕЛИ БИОСТАТИСТИКИ

ИСПОЛЬЗОВАНИЕ ТОЧЕЧНЫХ ПРОЦЕССОВ В АНАЛИЗЕ ДАННЫХ ТИПА ВРЕМЕНИ ЖИЗНИ



Санкт-Петербург

2024

МИНОБРНАУКИ РОССИИ

Санкт-Петербургский государственный электротехнический
университет «ЛЭТИ» им. В. И. Ульянова (Ленина)

С. В. МАЛОВ И. Ю. МАЛОВА

**БАЗОВЫЕ МОДЕЛИ БИОСТАТИСТИКИ
ИСПОЛЬЗОВАНИЕ ТОЧЕЧНЫХ ПРОЦЕССОВ В АНАЛИЗЕ
ДАННЫХ ТИПА ВРЕМЕНИ ЖИЗНИ**

Учебное пособие



Санкт-Петербург
Издательство СПбГЭТУ «ЛЭТИ»
2024

УДК 519.2(07)

ББК В 172я7

М19

Малов С. В., Малова И. Ю.

М19 Базовые модели биостатистики: использование точечных процессов в анализе данных типа времени жизни: учеб. пособие. СПб.: Изд-во СПбГЭТУ «ЛЭТИ», 2024. 80 с.

ISBN 978-5-7629-3321-6

Рассмотрено использование методов математической статистики и теории случайных процессов в анализе данных типа времени жизни.

Предназначено для поддержки дисциплины «Биостатистика» на ФКТИ СПбГЭТУ «ЛЭТИ», будет интересно студентам и аспирантам, обучающимся по программам подготовки специалистов в области информационных технологий.

УДК 519.2(07)

ББК В 172я7

Рецензенты: кафедра высшей математики ВШТЭ СПбГУПТД; д-р техн. наук, проф. Л. В. Уткин (СПбПУ им. Петра Великого).

Утверждено

редакционно-издательским советом университета

в качестве учебного пособия

553815



ISBN 978-5-7629-3321-6

Оглавление

Введение	3
1. ВВЕДЕНИЕ В ТЕОРИЮ СЛУЧАЙНЫХ ПРОЦЕССОВ	4
1.1. Случайные процессы и их распределения	4
1.2. Введение в теорию мартингалов	8
1.3. Понятия компенсатора и бикомпенсатора	10
1.4. Предельные теоремы	13
1.5. Точечные процессы	16
2. ЦЕНЗУРИРОВАННЫЕ СПРАВА ДАННЫЕ	20
2.1. Распределение времени отказа	22
2.2. Условие независимости цензурирования	23
3. АНАЛИЗ ОДНОРОДНЫХ ЦЕНЗУРИРОВАННЫХ СПРАВА ДАННЫХ	29
3.1. О вычислении компенсаторов	29
3.2. Непараметрическое оценивание накопленной интенсивности	32
3.3. Оценка Каплана–Мейера	39
4. ПРОВЕРКА ОДНОРОДНОСТИ ГРУПП НАБЛЮЖДЕНИЙ	42
4.1. Линейные ранговые статистики для проверки однородности двух групп	43
4.2. Обобщенные линейные ранговые статистики и их асимптотические свойства	47
5. СЕМИПАРАМЕТРИЧЕСКИЕ РЕГРЕССИОННЫЕ МОДЕЛИ	51
5.1. Регрессионные модели	51
5.2. Полное и частичное правдоподобие	55
5.3. Наблюдаемое правдоподобие и частичное правдоподобие по Коксу	59
5.4. Аддитивно-мультипликативная модель	63
5.5. Непараметрический регрессионный подход	73
Список рекомендуемой литературы	78

Введение

Настоящее издание предназначено для глубокого изучения методов анализа данных типа времени жизни с правым цензурированием. Анализ данных типа времени жизни остается актуальным направлением в современной математической и прикладной статистике, а основные его методы реализованы практически во всех статистических пакетах, таких, как R, SPSS, Statistica и SAS. Более того, модули статистического анализа данных такого типа присутствуют в программных средах MatLab, Python и др. Несмотря на имеющиеся сложности постановки экспериментов, связанных с изучением времени жизни, безотказной работы механизма или же наступления некоторого события, характеризующего переход изучаемого объекта в новое качество, приобретение или утрату им некоторого свойства, данные типа времени жизни являются важной и неотъемлемой частью научных исследований в различных областях знаний. Главная сложность обычно связана с значительной продолжительностью исследования, в связи с чем многие времена наступления событий остаются недостижимыми и в работу включается механизм цензурирования справа. Цензурирование может быть обусловлено не только истечением времени, отведенного на проведение эксперимента, но и внешними факторами, не позволяющими выявить точное время наступления события. Идея последовательного накопления статистической информации с течением времени идеально согласуется с понятиями фильтрации и стохастического базиса, играющими важную роль в теории случайных процессов. Применение точечных процессов позволяет не только получить строгие математические методы анализа для широкого класса моделей, но и создает базу для построения новых методов и расширения класса известных моделей анализа неполных данных типа времени жизни.

Основная часть учебного пособия состоит из четырех разделов. *Первый раздел* включает в себя введение в теорию случайных процессов, а также формирование основных понятий и необходимые результаты теории мартингалов с приложениями к точечным процессам, которые в дальнейшем будут использованы для построения асимптотических методов анализа данных типа времени жизни. Во *втором разделе* рассматриваются методы анализа однородных данных типа времени жизни. *Третий раздел* посвящен построению асимптотической теории линейных ранговых статистик, применяемых для проверки однородности распределений двух или

нескольких групп объектов исследования. В *четвертом разделе* изучаются модели анализа неоднородных данных типа времени жизни с правым цензурированием. Основное внимание уделяется мультипликативной и аддитивно-мультипликативной регрессионным моделям с возможностью использования зависящей от времени ковариаты. Будет построена асимптотическая теория, позволяющая строить доверительные множества и проверять статистические гипотезы о параметрах моделей.

Механизм *цензурирования справа* наиболее часто применяется в анализе данных типа времени жизни. Результат статистического эксперимента представляет собой пару времен отказа и цензурирования (T, U) , тогда как наблюдается только пара (X, δ) , где $X = T \wedge U$ и $\delta = \mathbb{I}_{\{T \leq U\}}$. Иными словами, наблюдается лишь наименьшее из времен T или U , при этом известно, какое из событий (отказ или цензурирование) произошло раньше. Отображение $\Phi : \mathbb{R}_+^2 \rightarrow \mathbb{R}_+ \times \{0, 1\}$ реализует соотношение $(T, U) \mapsto (X, \delta)$. Элементарными событиями наблюдаемой σ -алгебры \mathfrak{D} будут лучи вида $((x, \infty), \{x\})$ и $(\{x\}, [x, \infty))$ в \mathbb{R}^2 . В зависимости от модели рассматривают выборку из распределения (T, U) с правым цензурированием или независимые, но не одинаково распределенные наблюдения (несколько выборок, регрессионная модель). В последнем случае с каждой парой (T, U) и, соответственно, наблюдением (X, δ) ассоциировано значение ковариаты z . Отметим, что без дополнительных предположений о распределении (T, U) по выборке невозможно восстановить распределение времени отказа, так как оцениваемый параметр не идентифицируем. Наиболее часто предполагают, что времена отказа T и цензурирования U суть независимые случайные величины. Более слабое условие независимости цензурирования, позволяющее делать статистические выводы о распределениях времен цензурирования, будет рассмотрено позднее.

1. ВВЕДЕНИЕ В ТЕОРИЮ СЛУЧАЙНЫХ ПРОЦЕССОВ

1.1. Случайные процессы и их распределения

Пусть $(\Omega, \mathfrak{F}, \mathbb{P})$ – вероятностный эксперимент, Γ – множество, \mathfrak{D} – σ -алгебра подмножеств Γ . Семейство случайных величин $\{X_t\}_{t \in \Gamma}$ будем называть *случайным процессом*, заданным на множестве (Γ, \mathfrak{D}) .

Случайный процесс также можно определить как отображение $X : \Gamma \times \Omega \rightarrow \mathbb{R}$, такое, что при каждом фиксированном $t_0 \in \Gamma$ отображение

$X(t_0, \omega) : \Omega \rightarrow \mathbb{R}$ является случайной величиной. Функция $X(\cdot, \omega) : \Gamma \rightarrow \mathbb{R}$ называется *траекторией* случайного процесса, соответствующей исходу ω ($\omega \in \Omega$). Свойства траекторий $X(\cdot, \omega)$ переносятся на случайный процесс, если данное свойство выполнено с вероятностью 1 (почти наверное).

Распределение случайного процесса определяют конечномерные распределения (КМР)

$$P_{t_1, \dots, t_n}(A_1 \times \dots \times A_n) = \mathbb{P}(X_{t_1} \in A_1, \dots, X_{t_n} \in A_n), \quad A_1, \dots, A_n \in \mathcal{B}_1,$$

при всех $t_1, \dots, t_n \in T$ и $n \in \mathbb{N}$ удовлетворяющие условиям согласования:

- (i) для любой перестановки $(\sigma_1, \dots, \sigma_n)$ индексов $\{1, \dots, n\}$

$$P_{\sigma_1, \dots, \sigma_n}(A_{\sigma_1} \times \dots \times A_{\sigma_n}) = P_{t_1, \dots, t_n}(A_1 \times \dots \times A_n);$$

- (ii) для любого $n \in \mathbb{N}$ и любых $t_1, \dots, t_n \in T$

$$P_{t_1, \dots, t_{n-1}}(A_1 \times \dots \times A_{n-1}) = P_{t_1, \dots, t_n}(A_1 \times \dots \times A_{n-1} \times \mathbb{R}).$$

Замечания: 1. Свойства (i) и (ii) являются характеристическими свойствами КМР случайного процесса, т. е. для любого семейства распределений, удовлетворяющих условиям согласования, существует вероятностный эксперимент и заданный на нем случайный процесс, имеющий соответствующие КМР.

2. Многие свойства траекторий случайного процесса, например непрерывность, не всегда определяются распределением случайного процесса.

Случайные величины X и Y на одном вероятностном эксперименте *стохастически эквивалентны*, если $\mathbb{P}(X \neq Y) = 0$. Случайный процесс X_t называется *модификацией* процесса Y_t , если для любого $t \in \Gamma$ величины X_t и Y_t стохастически эквивалентны. Случайные процессы X_t и Y_t *неразличимы*, если $\mathbb{P}(\omega : X_t = Y_t, t \in \Gamma) = 1$. Ясно, что неразличимые процессы являются модификациями друг друга. Далее считаем, что $\Gamma = \mathbb{N}$ (последовательность), $\Gamma = [0, a]$ при некотором $a > 0$, или $\Gamma = \mathbb{R}_+$.

Поскольку непрерывность траекторий случайного процесса на \mathbb{R}_+ не определяется его распределением, важно определить достаточные условия непротиворечивого введения свойства непрерывности в определение случайного процесса. Следующая теорема Колмогорова устанавливает достаточные условия существования непрерывной модификации случайного процесса.