

С. В. Малов
И. Ю. Малова



БАЗОВЫЕ МОДЕЛИ БИОСТАТИСТИКИ

АНАЛИЗ РЕЗУЛЬТАТОВ ГЕНЕТИЧЕСКИХ

ИССЛЕДОВАНИЙ



САНКТ-ПЕТЕРБУРГ
2025

МИНОБРНАУКИ РОССИИ

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

С. В. МАЛОВ И. Ю. МАЛОВА

**БАЗОВЫЕ МОДЕЛИ БИОСТАТИСТИКИ
АНАЛИЗ РЕЗУЛЬТАТОВ ГЕНЕТИЧЕСКИХ
ИССЛЕДОВАНИЙ**

Учебное пособие



Санкт-Петербург
Издательство СПбГЭТУ «ЛЭТИ»
2025

УДК 519.2(07)

ББК В 172я7

М19

Малов С. В., Малова И. Ю.

М19 Базовые модели биостатистики. Анализ результатов генетических исследований: учеб. пособие. СПб.: Изд-во СПбГЭТУ «ЛЭТИ», 2025. 80 с.

ISBN 978-5-7629-3488-6

Рассмотрено использование методов математической статистики в анализе результатов генетических исследований.

Предназначено для поддержки дисциплины «Статистический анализ и основы биостатистики» 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

553814

ISBN 978-5-7629-3488-6



Оглавление

Введение	3
1. ГЕНЕТИЧЕСКИЕ ИССЛЕДОВАНИЯ	4
1.1. Генетические данные	4
2. ЗАДАЧА МНОЖЕСТВЕННОГО ТЕСТИРОВАНИЯ	6
2.1. Ошибки множественного тестирования	7
2.2. Методы контроля FWER	9
2.3. Методы контроля FDR	11
3. ПЛАНИРОВАНИЕ ЭКСПЕРИМЕНТА И ПОДГОТОВКА ДАННЫХ	13
3.1. Разработка плана исследования	13
3.2. Сбор и подготовка данных	15
3.3. Проверка равновесия Харди–Вайнберга	16
3.4. Проверка неоднородности популяции	19
3.5. Проверка родственных связей	22
4. СЦЕПЛЕНИЕ ГЕНЕТИЧЕСКИХ МАРКЕРОВ И ИМПУТИРОВАНИЕ	26
4.1. Модели эволюции гаплотипов	28
4.2. Сцепленность генетических маркеров	32
4.3. Фазирование генотипов	37
4.4. Скрытые марковские модели	38
4.5. Импутирование	43
5. СТАТИСТИЧЕСКИЕ МЕТОДЫ АНАЛИЗА ГЕНЕТИЧЕСКИХ АССОЦИАЦИЙ	47
5.1. Постановка задачи поиска генетических ассоциаций	48
5.2. Возможные подходы к улучшению поправки Бонферрони	50
5.3. Уточнение результатов поиска и анализ генетических ассоциаций	57
5.4. Анализ генетических ассоциаций и интерпретация результатов	58
5.5. Метаанализ	61
5.6. Использование методов машинного обучения в анализе результатов генетических исследований	66
6. АНАЛИЗ РЕЗУЛЬТАТОВ ГЕНЕТИЧЕСКИХ ИССЛЕДОВАНИЙ В ПАКЕТЕ R	69
6.1. Хранение и обмен данными	70

6.2. Подготовка данных к анализу генетических ассоциаций	72
6.3. Анализ генетических ассоциаций	73
Список рекомендуемой литературы	77

Введение

Различные свойства живого организма в значительной мере определяются его генетическими особенностями, или генетическим кодом. Генетический код содержит в себе важную информацию для производства белков, из которых строится сам организм, а также все системы, обеспечивающие его функционирование. Наличие генетической информации дает возможность предсказывать многие жизненно важные свойства организма.

Хранение и передачу генетической информации обеспечивает дезоксирибонуклеиновая кислота (ДНК). Молекула ДНК состоит из двух комплиментарных цепочек, химически связанных между собой и закрученных сложным образом. Каждая цепочка ДНК составлена из четырех азотистых оснований (нуклеотидов) – аденина (А), гуанина (G), тимина (Т) и цитозина (С). Молекула ДНК хранится в хромосомах. У диплоидных организмов (например, у человека) существуют парные хромосомы, ДНК в которых различаются незначительно. В результате секвенирования и последующей расшифровки исследователь получает генетический код, представляющий собой набор букв «А», «G», «Т», «С», разбитый на хромосомы. В процессе размножения происходят минимальные изменения генетического кода, называемые мутациями, которые в процессе эволюции приводят к значительному разнообразию видов. Среди мутаций наиболее распространены единичные замены, представляющие собой замену одного нуклеотида на другой в определенной позиции (локусе), – транзиции ($A \leftrightarrow G$; $T \leftrightarrow C$) и трансверсии ($A \leftrightarrow T$; $A \leftrightarrow C$; $G \leftrightarrow C$; $G \leftrightarrow T$). Встречаются и более сложные мутации – инсерции/делеции, инверсии, дупликации, транслокации. Мутации происходят постоянно, однако в случае многоклеточных организмов большинство мутаций не влияют на эволюцию, так как касаются только одного организма. Лишь мутации, происходящие в стволовых клетках, могут закрепиться в потомстве и влиять на ход эволюции.

Важнейшую роль в генетических исследованиях играет статистика, позволяющая получить рабочие гипотезы для установления связи между генотипом и интересующим свойством организма (фенотипом). Следует отметить, что статистика не гарантирует абсолютной достоверности полученных выводов, поэтому для надежного подтверждения связи генотипа и фенотипа, найденной статистическим путем, желательно получить иные аргументы, основанные на понимании причин этой связи. К сожалению, абсолютно достоверные аргументы подтверждения установленных связей генотипа с фенотипом удастся найти нечасто, поэтому статистические вы-

воды чаще всего остаются единственным средством установления и подтверждения установленных связей.

Все растущее число научных исследований порождает множество невоспроизводимых (ложноположительных) выводов, в связи с чем следует подходить с особой осторожностью к интерпретации результатов статистического анализа.

1. ГЕНЕТИЧЕСКИЕ ИССЛЕДОВАНИЯ

Особенность постановки статистического эксперимента для генетических исследований состоит в том, что для проведения статистического анализа требуются наличие одной или нескольких наблюдаемых характеристик (фенотипов) и наборы генетических маркеров (генотипов) каждого объекта исследования.

Фенотипы могут представлять собой результаты проведения клинических исследований, значение определенного или нескольких внешних признаков объекта исследования, а также их этногеографические характеристики. В биомедицинских исследованиях для получения фенотипов реализуют стандартные планы биостатистики.

1.1. Генетические данные

Генотипы обычно представляют собой наборы генетических маркеров. Вариации в одной позиции исследуемого участка ДНК (локуса), закрепившиеся в популяции, получили название однонуклеотидных полиморфизмов (ОНП)¹. Ввиду наличия парных хромосом у диплоидных организмов ОНП представляет собой неупорядоченный набор аллелей, где каждую аллель определяет вариант нуклеотида фиксированного индивида в данной позиции на соответствующей хромосоме. Вероятность закрепления в популяции более двух вариантов ОНП в одной позиции крайне мала. Хотя существует широкий класс мультивариантных ОНП, в пределах одной популяции мультивариантные ОНП обычно имеют два варианта. Наличие идентичных нуклеотидов в данной позиции на обеих парных хромосомах называется гомозиготным вариантом (например, *AA*, *TT*), тогда как при наличии различных вариантов (например, *AT*, *AG*) – гетерозиготным. При наличии двух вариантов аллелей ОНП представляет собой признак с тремя уровнями, включающими 2 гомозиготных варианта и один – гетерозиготный. Варианты более сложных мутаций тоже довольно часто сводят к биаллельным, группируя все варианты, отличные от одного выбранного.

¹Single Nucleotide Polymorphism (SNP), *англ.*

Для определения местоположения генетического маркера используются его координаты, состоящие из номера хромосомы (парные хромосомы имеют один и тот же номер) и его позиции на хромосоме. Генетические варианты обычно определяются сравнением генетических данных изучаемой популяции с референсным геномом, представляющим собой характерную последовательность букв *A, G, C, T*. Большая часть последовательности всех представителей популяции совпадает с референсным геномом, в остальных же позициях определяются генетические варианты. Длина генома человека приблизительно равна $3.2 \cdot 10^9$ пар нуклеотидов. На текущий момент описано более 500 млн ОНП в организме человека. Разумеется, число ОНП в ограниченной популяции случайно и зависит от ее размера, поэтому в рамках одного исследования находится гораздо меньше ОНП. В частности, число ОНП в популяции 1000 человек все еще достаточно велико и может достигать 10 млн. Более сложных мутаций, разумеется, гораздо меньше. В исследуемой популяции чаще встречающийся вариант аллели обычно называют общим («common», «wild type»), а альтернативный – редким («minor»).

Существует 2 основных подхода для получения генетических данных – полногеномное секвенирование и ДНК-микрочипы. Полный набор вариантов получают в результате полногеномного секвенирования. В основе метода лежит репликация коротких фрагментов ДНК и «выравнивание» их на референсный геном. Общее число генетических вариантов зависит от размера популяции. К сожалению, в результате полногеномного секвенирования далеко не всегда удается точно восстановить каждый генетический вариант. Обычно ненадежные варианты отфильтровываются на базе специальных показателей, вычисляемых при выравнивании, но и это не гарантирует, что все остальные варианты генотипированы корректно. Кроме того, полногеномное секвенирование – очень дорогой способ получения генетических данных. Более дешевый способ – использование ДНК-микрочипов, позволяющих определить значения только фиксированного набора генетических маркеров. Современные стандартные ДНК-микрочипы позволяют определять до $5 \cdot 10^6$ генетических вариантов, тогда как более старые ДНК-микрочипы содержали менее $5 \cdot 10^5$ генетических вариантов. Возможен заказ специализированных ДНК-микрочипов, ориентированных на определенные исследования. Основной недостаток секвенирования на базе ДНК-микрочипов – невозможность определения новых вариантов. Как и в случае полногеномного секвенирования, при использовании ДНК-микрочипов возможны ошибки. Ввиду относительной дешевизны технологии ДНК-микрочипы позволяют секвенировать большие популяции.