

# АНАЛИЗ ДАННЫХ В ИММУНОЛОГИИ

Ст. преподаватель  
ЖИВИЦКАЯ ЕЛЕНА ПЕТРОВНА

# ЗАДАЧИ ИММУНОЛОГИЧЕСКИХ ИССЛЕДОВАНИЙ

1. Определение связи между несколькими иммунологическими и/или иными показателями без предположения о том, что они вызывают друг друга (не рассматривая их как следствие друг друга).
2. Исследование связи между иммунологическим показателем и клиническими данными, рассматривая их как следствие друг друга. В данном случае иммунологический показатель относится к независимым признакам и рассматривается в качестве фактора риска, а в качестве зависимых признаков выступают клинические данные (исход заболевания, тяжесть течения, стадия патологического процесса).
3. Комплексное исследование, включающее два или более объекта, описанных выше.
4. Компьютерное конструирование иммунологических процессов, заключающееся в прогнозировании иммуногенных последовательностей микробного генома, идентификации регуляторных молекул иммунного ответа и т. д.

# Этапы анализа данных

Ввод данных

Преобразование данных

Визуализация данных

Статистический анализ

Собственно выбор метода, анализ  
данных и интерпретация результатов

Представление результатов

# ОСНОВНЫЕ ПОНЯТИЯ СТАТИСТИКИ

**Совокупность** – это всякое множество отдельных объектов, отличающихся друг от друга и в то же время сходных по некоторым существенным признакам.

**Генеральная совокупность** – теоретически бесконечно большая совокупность всех единиц, которые могут быть к ней отнесены.

**Выборочная совокупность** – относительно небольшая выборка из генеральной совокупности, которая подвергается изучению.

**Объем совокупности** – число единиц совокупности.

**Генеральная совокупность**

**Выборочная совокупность**



**Репрезентативность** - свойство выборочной совокупности отражать основные, важные для исследования, характеристики генеральной совокупности.

Репрезентативность определяет, насколько возможно обобщать результаты исследования с привлечением определённой выборки на всю генеральную совокупность, из которой она была собрана.

# Типы данных

Количественные

Качественные

Дискретные

Непрерывные

Номинальные

Порядковые

Дихотомические

# Типы данных

- **Количественные**
  - Различия равновелики
  - **Непрерывные** (напр., кровяное давление, масса тела, рост, возраст, биохимические показатели крови)
  - **Дискретные** (напр., кол-во беременностей, кол-во детей и др.; выражаются только целыми числами)

# Типы данных

- Качественные

*Порядковые (отражают условную степень выраженности признака)*

- Можно ранжировать, но различия между категориями не обязательно равновелики
  - Напр., маленький/средний/большой, или состояние тяжести пациента

# Типы данных

- Качественные

*Номинальные (отражают условные коды неизмеряемых категорий)*

- Коды диагнозов
- Коды пола: мужской, женский
- Раса: белая, черная, желтая
- Семейное положение
- **Дихотомические**: только 2 категории (да/нет, т.е. заболел/не заболел, умер/жив)

Для различных  
переменных и шкал  
применяются  
разные методы  
статистического  
анализа !!!

# Виды статистических пакетов

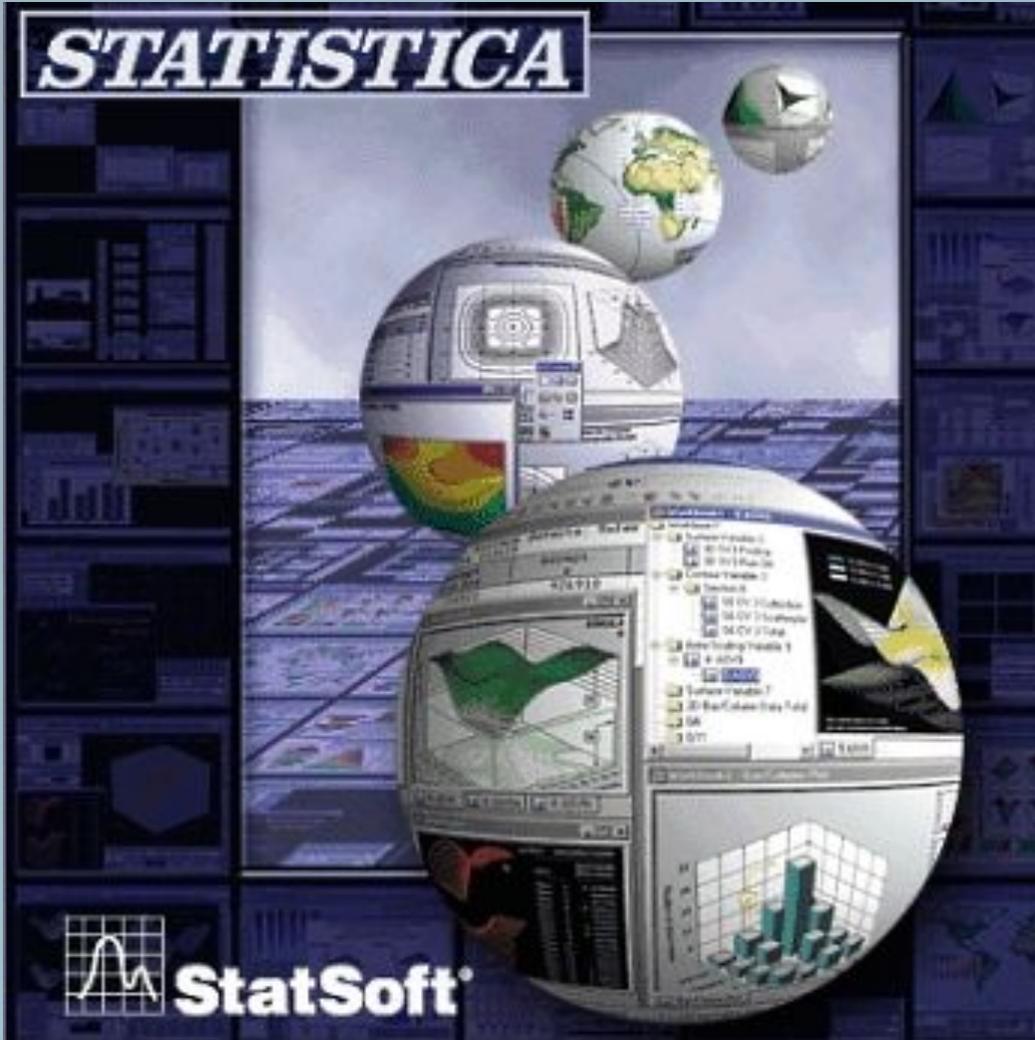
## *Универсальные пакеты*

- отсутствие прямой ориентации на специфическую предметную область, предлагают широкий диапазон статистических методов (SPSS, Statistica, пакет анализа в Excel)

## *Специализированные пакеты*

- обычно содержат методы из одного-двух разделов статистики или методы, используемые в конкретной предметной области (WinSTAT, Statit, STADIA)

STATISTICA - это универсальная интегрированная система, предназначенная для статистического анализа и визуализации данных, управления базами данных и разработки пользовательских приложений, содержащая широкий набор процедур анализа для применения в научных исследованиях .



## Система обладает следующими общепризнанными достоинствами:

- ❑ содержит полный набор классических методов анализа данных;
- ❑ отвечает всем стандартам Windows;
- ❑ легка в освоении;
- ❑ данные системы STATISTICA легко конвертировать в различные базы данных и электронные таблицы;
- ❑ поддерживает высококачественную графику, позволяющую эффектно визуализировать данные и проводить графический анализ.

# Основные формы представления выборки из генеральной совокупности

1. Представление выборки в несгруппированном виде, путём обычного перечисления вариантов -  $x$ :

$$x_1, x_2, x_3, \dots, x_n.$$

2. Представление выборки в упорядоченном виде: расположение вариантов либо в порядке возрастания (чаще всего) либо в порядке убывания.

**1 1 2 2 2 3 3 3 3 4 4 4 4 5 5 5 6 6 6 7 7**

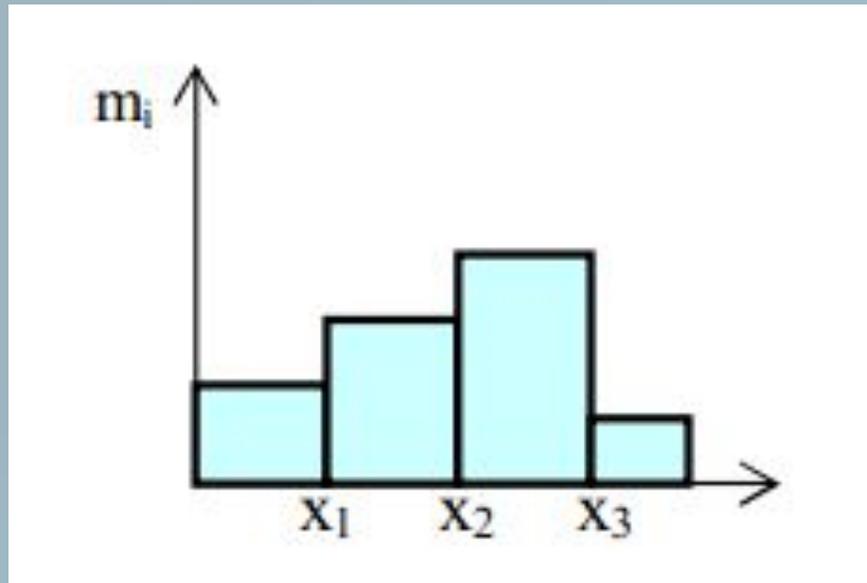
3. Представление выборки в сгруппированном виде, когда вместе с вариантами указываются числа (называемые частотами), равными числу повторений данной варианты в выборке.

<b>Значения</b>	<b><math>x_1</math></b>	<b><math>x_2</math></b>	<b>...</b>	<b><math>x_n</math></b>
<b>Частоты</b>	<b><math>p_1</math></b>	<b><math>p_2</math></b>	<b>...</b>	<b><math>p_n</math></b>
<b>Относительные частоты</b>	<b><math>m_1</math></b>	<b><math>m_2</math></b>	<b>...</b>	<b><math>m_n</math></b>

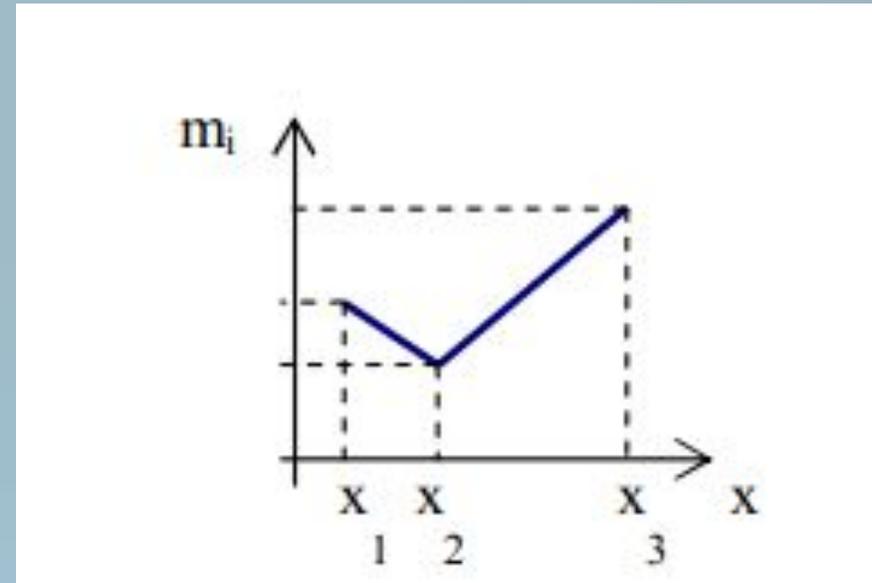
**$m=p/n$ , где  $n$  – объем выборки**

# Способы графического изображения данных

Гистограмма




Полигон распределения



Первым этапом анализа количественных данных является анализ вида их распределения

# Кривая нормального распределения



- 68% всех наблюдений лежат в диапазоне  $\pm 1$  стандартное отклонение от среднего, а диапазон  $\pm 2$  стандартных отклонения содержит 95% значений
- Числовые характеристики мода, медиана и среднее совпадают, распределение симметрично

## Проверка соответствия распределения нормальному закону

- ❑ выборочные среднее, медиана и мода должны быть близки по значению и находиться примерно посередине между 25 и 75 процентилями;
- ❑ интервал  $\pm$  два стандартных отклонения должен включать примерно 95% значений выборки и не должен содержать значений, которых не может быть в данном распределении (например, отрицательных).

# Статистические критерии для проверки нормальности распределения

- Критерий согласия  $\chi^2$  Пирсона (Pearson).
- Критерий Колмогорова-Смирнова (Kolmogorov-Smirnov). Применяется, если среднее значение и стандартное отклонение признака известны априори. *(для больших выборок)*
- Критерий Лиллиефорса (Lilliefors). Применяется, если среднее значение и стандартное отклонение признака неизвестны и вычисляются по выборке.
- Критерий Шапиро-Уилка (Shapiro–Wilk). Также применяется при априори неизвестных параметрах, является наиболее мощным, универсальным и строгим. *(для малых выборок)*

## Как часто встречается нормальное распределение???

- Можно сказать, что из всех распределений в природе чаще всего встречается именно нормальное распределение – отсюда и произошло его название.
- Но для данных биомедицинских исследований это не всегда верно. Нормальное распределение встречается в биомедицинских признаках примерно в 20-25%.
- До тех пор пока выборка достаточно большая (например, 30 (100) или больше наблюдений), можно считать, что выборочное распределение нормально.

# Статистические методы

- Описание данных
- Оценка статистической значимости результатов исследования (проверка гипотез)

# Способы описания данных

## Точечные характеристики

- Мода
- Медиана
- Средняя

## Характеристики вариации

- Размах колебаний
- Дисперсия
- Стандартное отклонение

## Точечные характеристики (меры центральной тенденции)

- **Среднее арифметическое (среднее)**
- **Медиана (Me)** - это средняя (центральная) варианта, делящая ряд распределения пополам, на две равные части. *Применяется только для ранжированного (упорядоченного по убыванию или возрастанию) ряда значений признака.*
- **Мода (Mo)** - наиболее часто встречающаяся в ряду распределения варианта

# Характеристики вариации (меры рассеяния)

**Стандартное отклонение** ( $\sigma$ ) – величина, отражающая вариабельность данных относительно **средней арифметической**

**Межквартильный размах** (для медианы) – показывает значения 25-го и 75 перцентилей, т.е. тот интервал, который включает в себя 50% данных в выборке

*Пример описания: Ме (25%÷75% перцентили) = 70 (35÷89)*

**Интерперцентильный размах** – значения перцентилей распределения данных (например, интервал между 10-м и 90-м перцентильями)

**Размах** – разность максимального и минимального значений данных

## Описание данных

Описание данных зависит от их **типа** (качественные или количественные) и **способа их распределения** !

## Описание данных в зависимости от их типа

Количественные

Для описания используется **среднее или медиана**

Качественные (номинальные)

Для описания используется **мода**

Качественные (порядковые)

Для описания используется **медиана**

# Какую среднюю величину использовать?

Нормальное  
или  
ненормальное  
распределение ?

# Методы описания данных

- **Параметрический метод:** для нормально распределенных количественных данных
  - Для описания используется **среднее арифметическое и стандартное отклонение**
- **Непараметрический метод:** для не нормально распределенных количественных данных и качественных данных
  - Для описания используется **медиана и межквартильный размах**
  - Медиана менее чувствительна к асимметрии и «выскакивающим» значениям

Задача	Параметрические методы	Непараметрические методы
Выполнение описательной статистики	Вычисление среднего, стандартного отклонения	Вычисление медиан и интерквартильных интервалов, долей
Сравнение двух независимых групп по одному признаку	Критерий Стьюдента	Критерии Манна-Уитни, Колмогорова-Смирнова, Вальда-Вольфовица, $\chi^2$ , точный критерий Фишера
Сравнение двух зависимых групп по одному признаку	Критерий Стьюдента для зависимых выборок	Критерий Вилкоксона, критерий знаков, критерий МакНимара
Сравнение трех и более независимых групп по одному признаку	Дисперсионный анализ	Критерий Краскела-Уоллиса, медианный критерий, $\chi^2$
Сравнение трех и более зависимых групп по одному признаку	Дисперсионный анализ для зависимых выборок	Критерий Фридмана, критерий Кохрена
Анализ взаимосвязи двух признаков	Коэффициент корреляции Пирсона, линейная регрессия	Коэффициенты корреляции Спирмена, Кендалла, гамма, точноно-бисериальный и рангово-бисериальный коэффициенты корреляции, коэффициент сопряженности, логистическая регрессия и др.