

# Многомерные методы анализа данных и моделирования медицинских систем

Долецкий А.Н.

---



# ПЛАН

- 1 Многомерные методы анализа данных
- 2 Задачи исследования сложных систем.
- 3 Дискриминантный анализ.
- 4 Анализ временных рядов. Кластерный анализ.

# Определение

- Методы многомерного анализа (англ. *multivariate* или *multivariable analysis*) разработаны для оценки влияния более чем одного фактора на результат, а также об эффекте взаимодействия этих переменных между собой.
  - В отечественной литературе многомерный анализ часто называют многофакторным анализом.
- 
- 

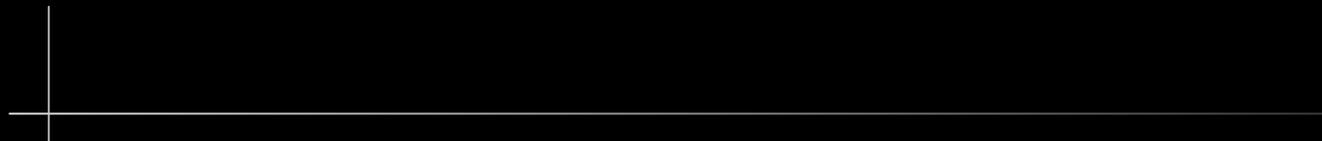
# Пример

- Пациенты травматологического отделения, оперированные в 9 часов утра, имеют более высокий показатель смертности, чем пациенты, оперированные в 9 часов вечера.
  - Анализируя смертность после операции одномерным (параметрическим или непараметрическим) статистическим методом, исследователь, допустим, действительно может обнаружить достоверную разницу.
- 
- 

# Пример

- Время суток не является единственным определяющим фактором.
- В анализ должны быть включены тяжесть травмы, возраст больного, плановые или срочные показания к операции, и т. п.

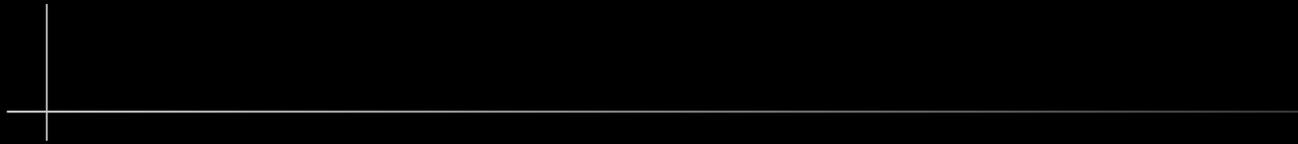
После этого вклад времени операции окажется очень малым по сравнению с истинными причинами.



# Терминология

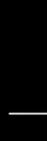
- Факторы (причины), влияющие на исход - факторы риска (risk factors), независимые (independent) или объясняющие переменные (explanatory variable)
  - Исход (outcome) – зависимая (dependent) или переменная отклика (response variable) или эффект.
- 
- 

# NB

- Факторы риска — не воздействия в процессе эксперимента!
  - Экспериментальная проверка совместного влияния многих факторов в клинической практике чаще всего просто невозможна или недопустима по этическим соображениям.
  - *Повышает ли курение вероятность ИБС в двух случайных выборках людей, одни из которых курят, другие – нет?*
- 
- 

- На связь между курением и ИБС могут влиять мешающие факторы (confounders).

?



- многомерный анализ является не единственным статистическим методом учета влияния или исключения конфаундеров.
  - Оценить влияние фактора риска на исход можно также с помощью **условного анализа** - изучаемая группа разбивается на подгруппы (страты), в которых потенциально мешающая переменная «фиксируется».
  - При этом модель применяется отдельно на каждой группе данных.
  - Например, мужской и женский пол: только курящие или некурящие мужчины и только курящие или некурящие женщины.
  - **Условный анализ эффективен когда изучается относительно небольшое число факторов (два-три).**
- 
- 

# Регрессия

В зависимости от задачи и типов данных чаще всего используется

- множественная линейная регрессия (multiple linear regression),
  - множественная логистическая регрессия (multiple logistic regression) и
  - модель пропорциональных интенсивностей Кокса (Cox proportional hazards model).
- 
- 

# Множественная линейная регрессия

- Независимые переменные - **непрерывные численные интервальные или относительные.**
  - Значения независимых переменных и зависимой переменной (исхода) изменяются линейно.
  - Величина коэффициента при независимой переменной и его знак в конечной модели показывают степень и характер взаимосвязи между этой переменной и исходом.
- 
- 

# Множественная линейная регрессия

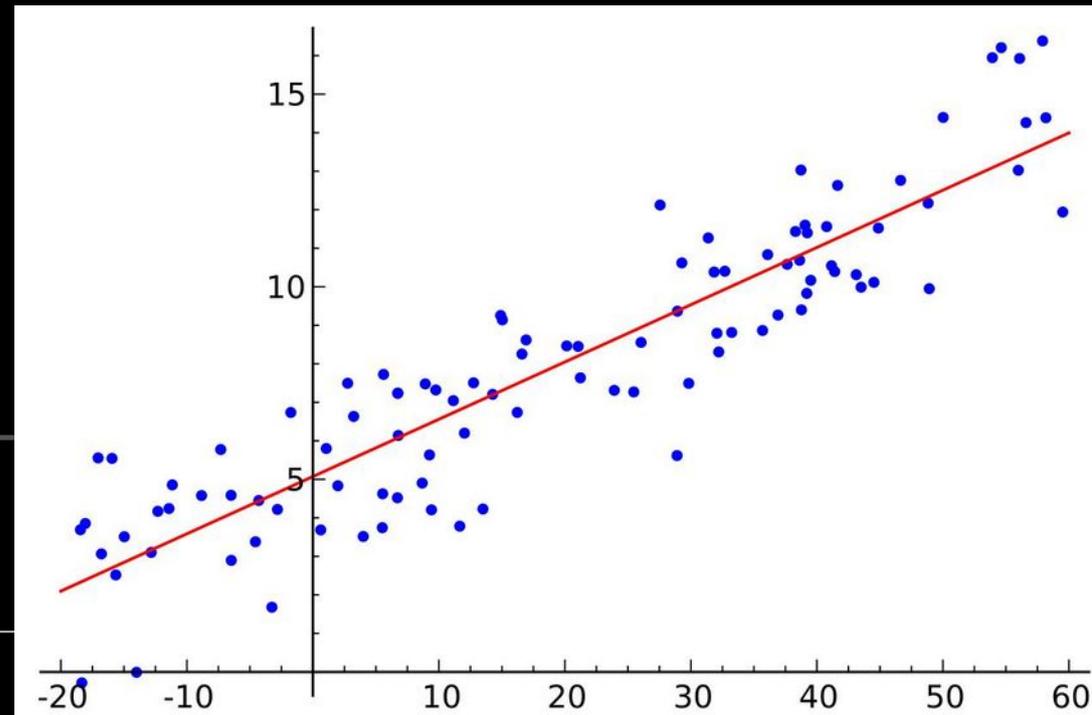
- модель оценки костной плотности у женщин в менопаузе, в которую входят возраст и индекс массы тела.



# Предназначение создаваемой модели

- Объясняющая модель.
- Прогностическая модель.

Могут быть включены коррелирующие независимые переменные, и модель будет хорошо работать. Но оцененные коэффициенты модели для таких переменных не имеют самостоятельного значения и не несут информации о степени влияния на эффект.



# Анализ качества модели

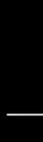
- Для оценки эффективности множественной линейной регрессии используется коэффициент детерминации  $r^2$ .
  - Отражает степень рассеяния результата, возникающего благодаря вкладу многих переменных. Значение  $r^2$  варьирует в пределах от 0 до 1 и чем ближе оно к 1, тем лучше модель описывает результат.
- 
- 

# Логистическая регрессия

Значение переменной результата является **бинарным**:

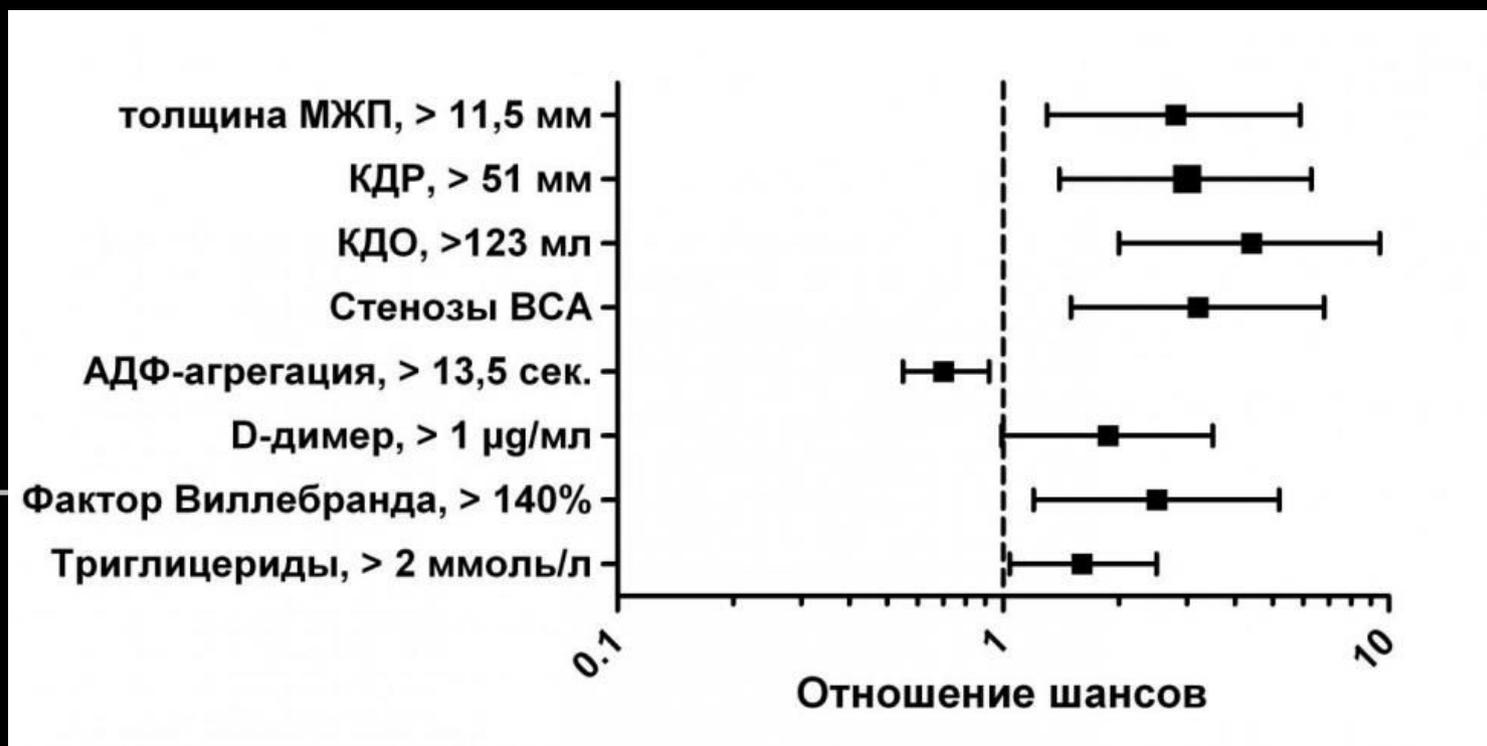
- выживаемость (да/нет),
- развитие заболевания (да/нет),
- положительный результат диагностического теста (да/нет).

**Относительный риск** (relative risk – RR), **отношение шансов** (odds ratio - OR) и границы их доверительных интервалов (confidence intervals - CI), а также степень достоверности (величину  $p$ ) отличия этих величин от 1 (значение при нулевой гипотезе).

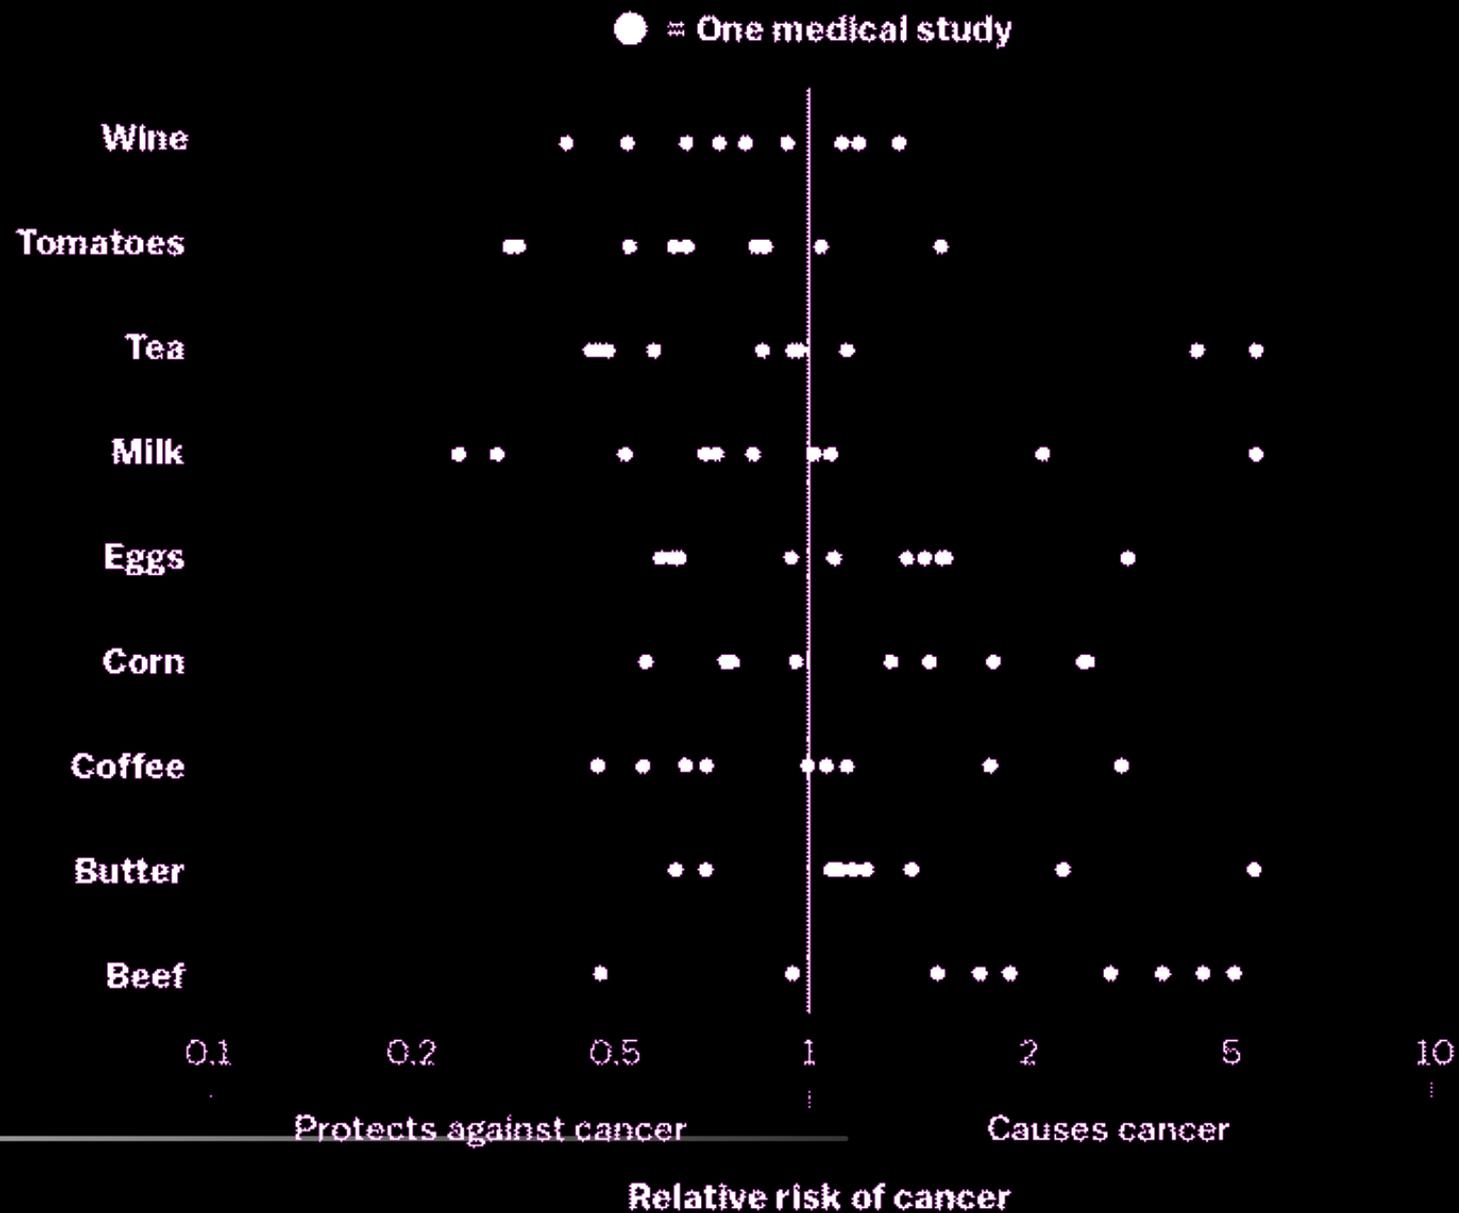


# Логистическая регрессия

OR близкое к 1 свидетельствует о слабой взаимосвязи. Широкий CI — низкая надежность оценки и необходимость перепроверки данных. Если границы CI включают значение 1, связь независимой переменной с исходом не может быть признана достоверной.



# Everything we eat both causes and prevents cancer



SOURCE: Schoenfeld and Ioannidis, *American Journal of Clinical Nutrition*

Vox

Ioannidis, Why most published research findings are false, 2005.

# Модель пропорциональных рисков Кокса

Зависимая переменная представляет время наступления определенного события.

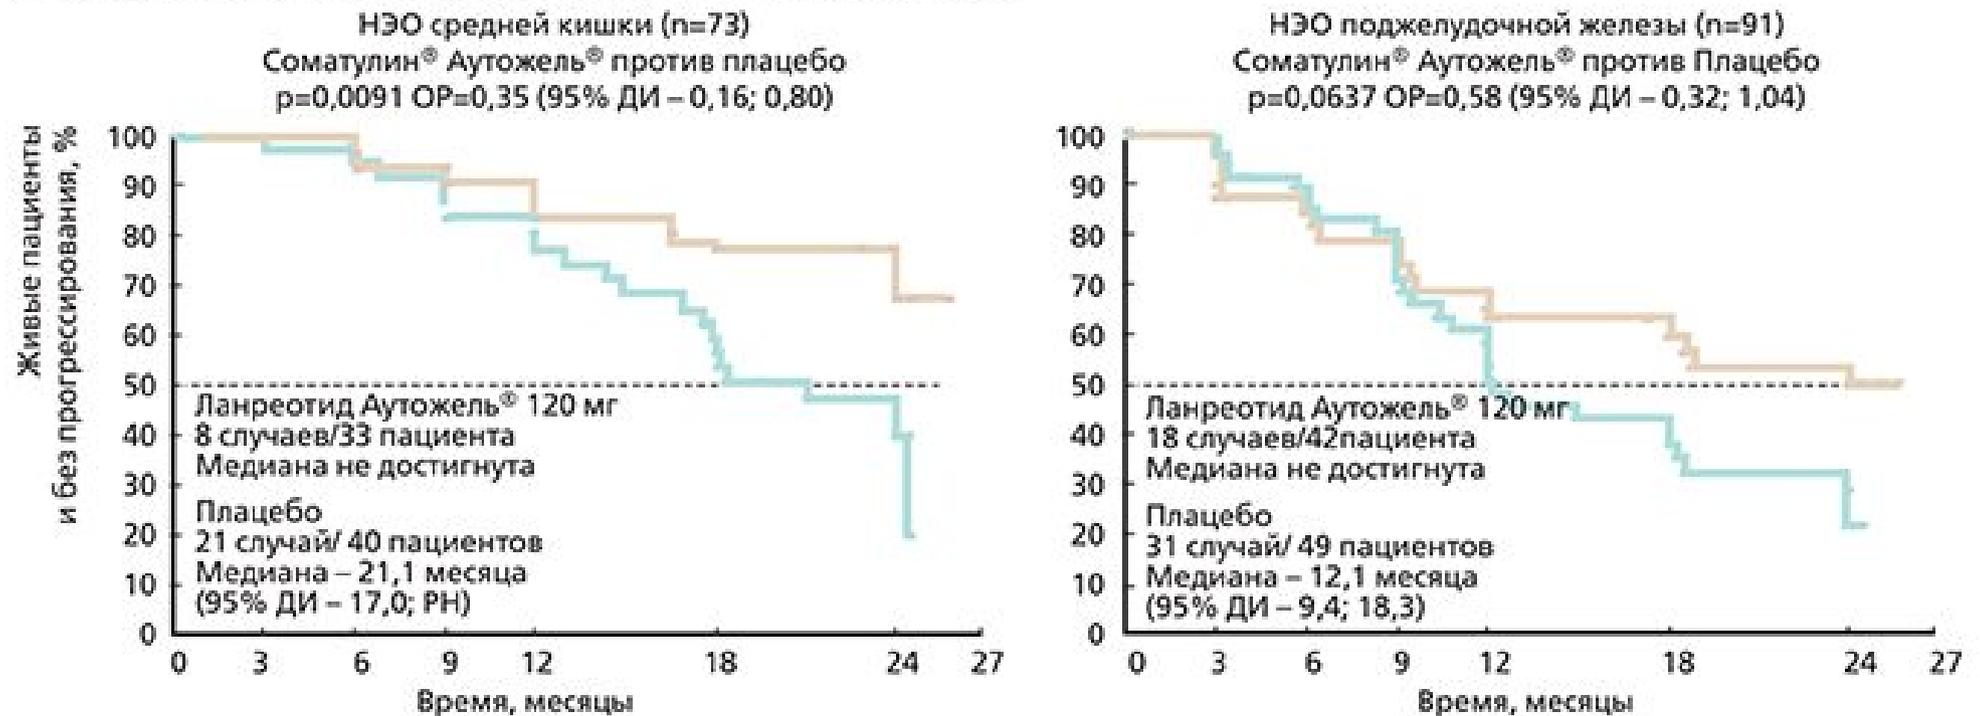
Оценивает шансы более раннего наступления события у членов изучаемой группы по сравнению с контрольной группой с помощью показателя отношения рисков (HR).

*HR=2 — пациент, получающий препарат и у которого выздоровление еще не наступило, имеет в 2 раза больший шанс выздороветь к следующему моменту времени, чем тот, кто получал плацебо.*

---



# Модель пропорциональных рисков Кокса



Значение  $p$  получено на основании стратифицированного лог-рангового критерия;  
ОР (отношение рисков) – получено на основании модели пропорциональных рисков Кокса.

Примечание. PH – рассчитать невозможно.

Caplin M., et al. North American Neuroendocrine Tumor Symposium, Charleston, South Carolina, USA, 2013.

# ФАКТОРНЫЙ АНАЛИЗ

Существует латентная переменная, с помощью которой можно объяснить наблюдаемое сходство полученных оценок. Такую латентную переменную называют фактором, который влияет на показатели других переменных.

цели факторного анализа:

1. определение взаимосвязей между переменными, их классификация, т. е. «объективная R-классификация»;
2. сокращение числа переменных.

	Фактор					
	1	2	3	4	5	6
<b>Результаты фрактального (энтропийного) анализа</b>						
индекс Херста	-0,03	0,04	-0,14	-0,28	0,15	<b>0,78</b>
индекс Дельта	0,04	-0,04	0,02	0,22	-0,11	<b>0,71</b>
<b>Средняя амплитуда ритмов в частотных диапазонах</b>						
Дельта	0,63	0,28	-0,60	-0,05	-0,01	0,03
Тета	<b>0,87</b>	0,27	0,01	0,01	0,01	-0,09
Альфа	<b>0,76</b>	0,22	0,31	0,00	0,17	0,10
Бета-1	<b>0,91</b>	-0,14	0,06	0,18	0,01	-0,04
Бета-2	<b>0,82</b>	-0,38	-0,12	0,10	0,02	0,15
<b>Результаты автокорреляционного анализа</b>						
Средняя частота	0,00	<b>-0,93</b>	0,05	0,07	0,03	-0,02
Интервал корреляции	-0,17	0,03	<b>-0,90</b>	-0,07	0,10	0,06
Коэффициент корреляции	0,14	0,43	<b>0,74</b>	-0,10	0,00	0,16
<b>Результаты кросскорреляционного анализа</b>						
Средняя частота	-0,07	<b>-0,95</b>	-0,14	-0,01	-0,08	0,04
Задержка	-0,07	0,07	0,24	0,19	<b>-0,71</b>	0,17
Коэффициент корреляции	0,08	0,13	0,20	0,29	<b>0,81</b>	0,21
<b>Результаты когерентного анализа</b>						
Средняя когерентность	0,01	-0,05	0,02	<b>0,87</b>	0,39	0,03
Доминирующая частота	0,12	0,00	-0,57	0,22	-0,06	0,32
Средняя частота	0,19	-0,06	-0,18	<b>0,81</b>	-0,30	-0,01

# Дискриминантный анализ

- Дискриминантный анализ проводится с целью выявления различий между исследуемыми группами.
  - *Цель анализа — выяснить, можно ли составить «типичный портрет покупателя» для каждой исследуемой группы по заданным характеристикам.*
- 
- 

# Дискриминантный анализ

- Система уравнений дискриминантного анализа:

- $S_i = c_i + w_{i1} * x_1 + w_{i2} * x_2 + \dots + w_{im} * x_m$

$S_i$  - результат показателя классификации;

$i$  – номер группы;

индексы 1, 2, ...,  $m$  – переменных (номер исследования);

$c_i$  - константа для  $i$ -ой группы;

$x_j$  — наблюдаемое значение  $j$ -ой переменной.

# Дискриминантный анализ

```
## [1] "LDA - зависимость ESS от качества сна, тревожности и депрессии"  
##  
## Coefficients:  
##      Estimate Std. Error t value Pr(>|t|)  
## (Intercept) 14.11995    0.94663  14.916 < 2e-16 ***  
## Сумма      -0.32398    0.04428  -7.318 5.33e-13 ***  
## Сумма_3     0.12650    0.05064   2.498 0.0127 *  
## Сумма_4     0.11066    0.06730   1.644 0.1005  
## ---  
## Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1  
##  
## Residual standard error: 3.75 on 961 degrees of freedom  
## (56 observations deleted due to missingness)  
## Multiple R-squared:  0.1113, Adjusted R-squared:  0.1085  
## F-statistic: 40.1 on 3 and 961 DF,  p-value: < 2.2e-16
```

---



# РАННЯЯ ДИАГНОСТИКА РАЗВИТИЯ ТОКСИКОЗА

- норма =  $0.865\text{СрАД} - 0.126\text{СИ} + 1.2\text{ФВ} - 71.1$
- гестоз =  $\text{СрАД} - 0.168\text{СИ} + 1.1\text{ФВ} - 77.446$

# Выделение групп с различной успешностью обучения

Весовые коэффициенты параметров при вычислении показателя классификации для групп с различной успешностью обучения БОС

Исследование	параметр	группа 1	группа 2	группа 3
ЭЭГ	Мощность дельта-ритма	2,40	2,23	2,37
ЭЭГ	Амплитуда дельта-ритма	-0,09	0,16	-0,01
ЭЭГ	Мощность альфа-ритма	2,24	2,05	2,20
Константа		-86,9	-97,9	-88,4

Прогноз успешности РЭГ-БОС

Мощность Дельта-активности: 14

Амплитуда Дельта-активности: 121

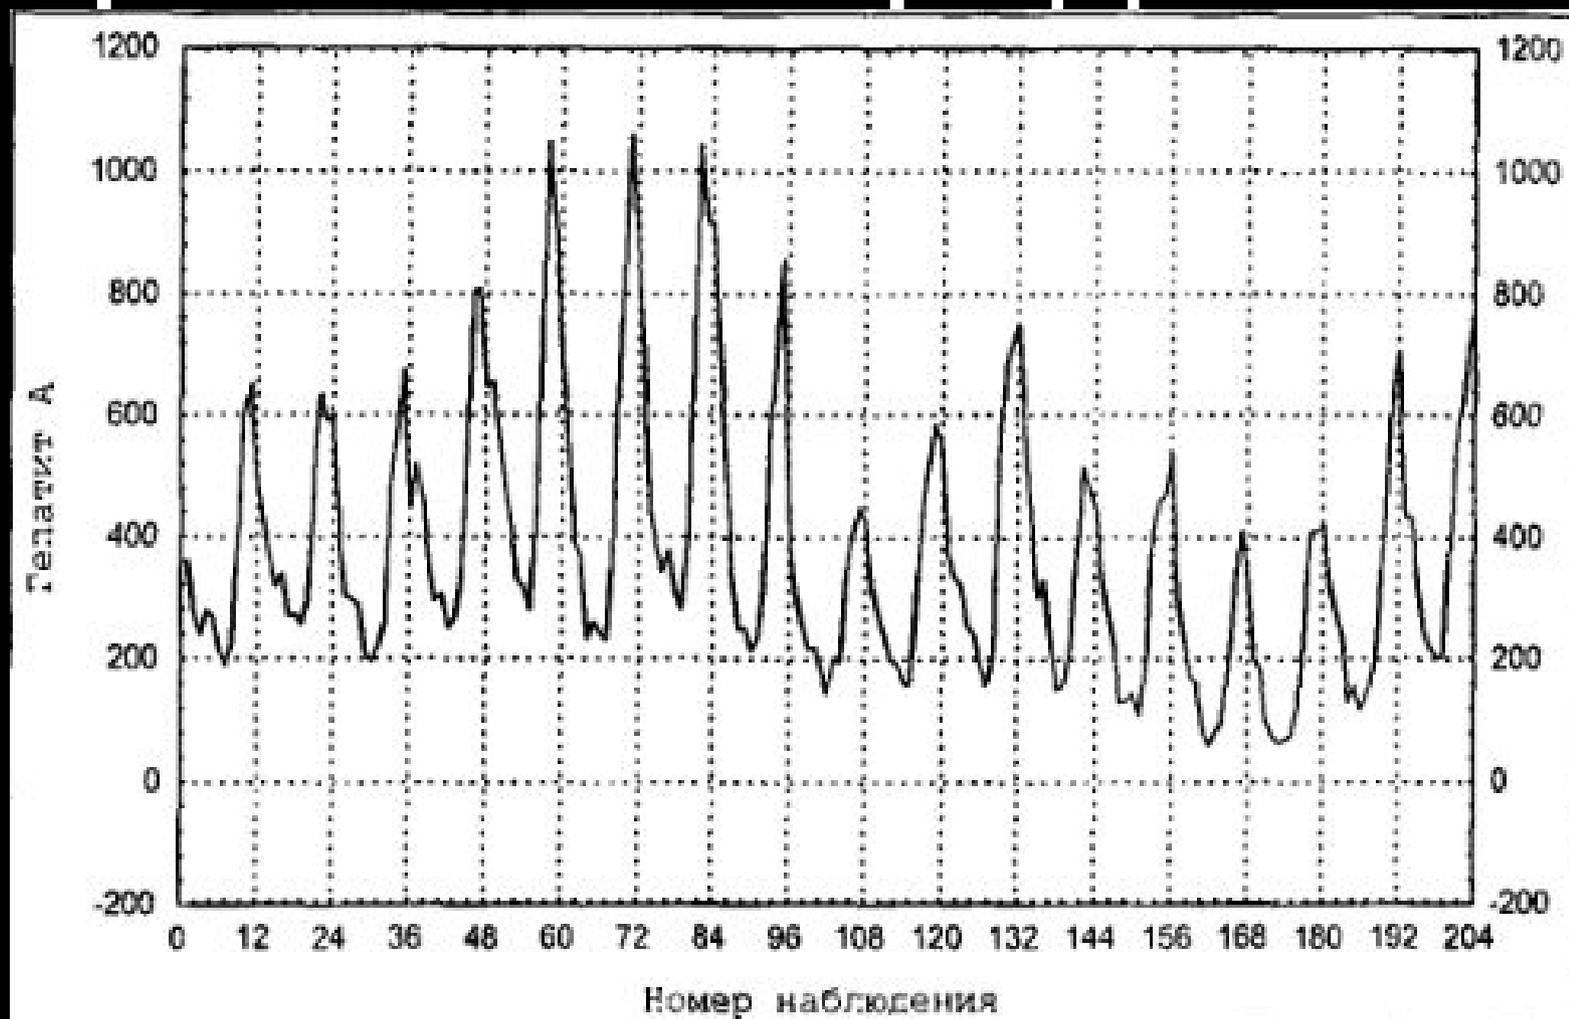
Мощность Альфа-активности: 44

Считать

Выход

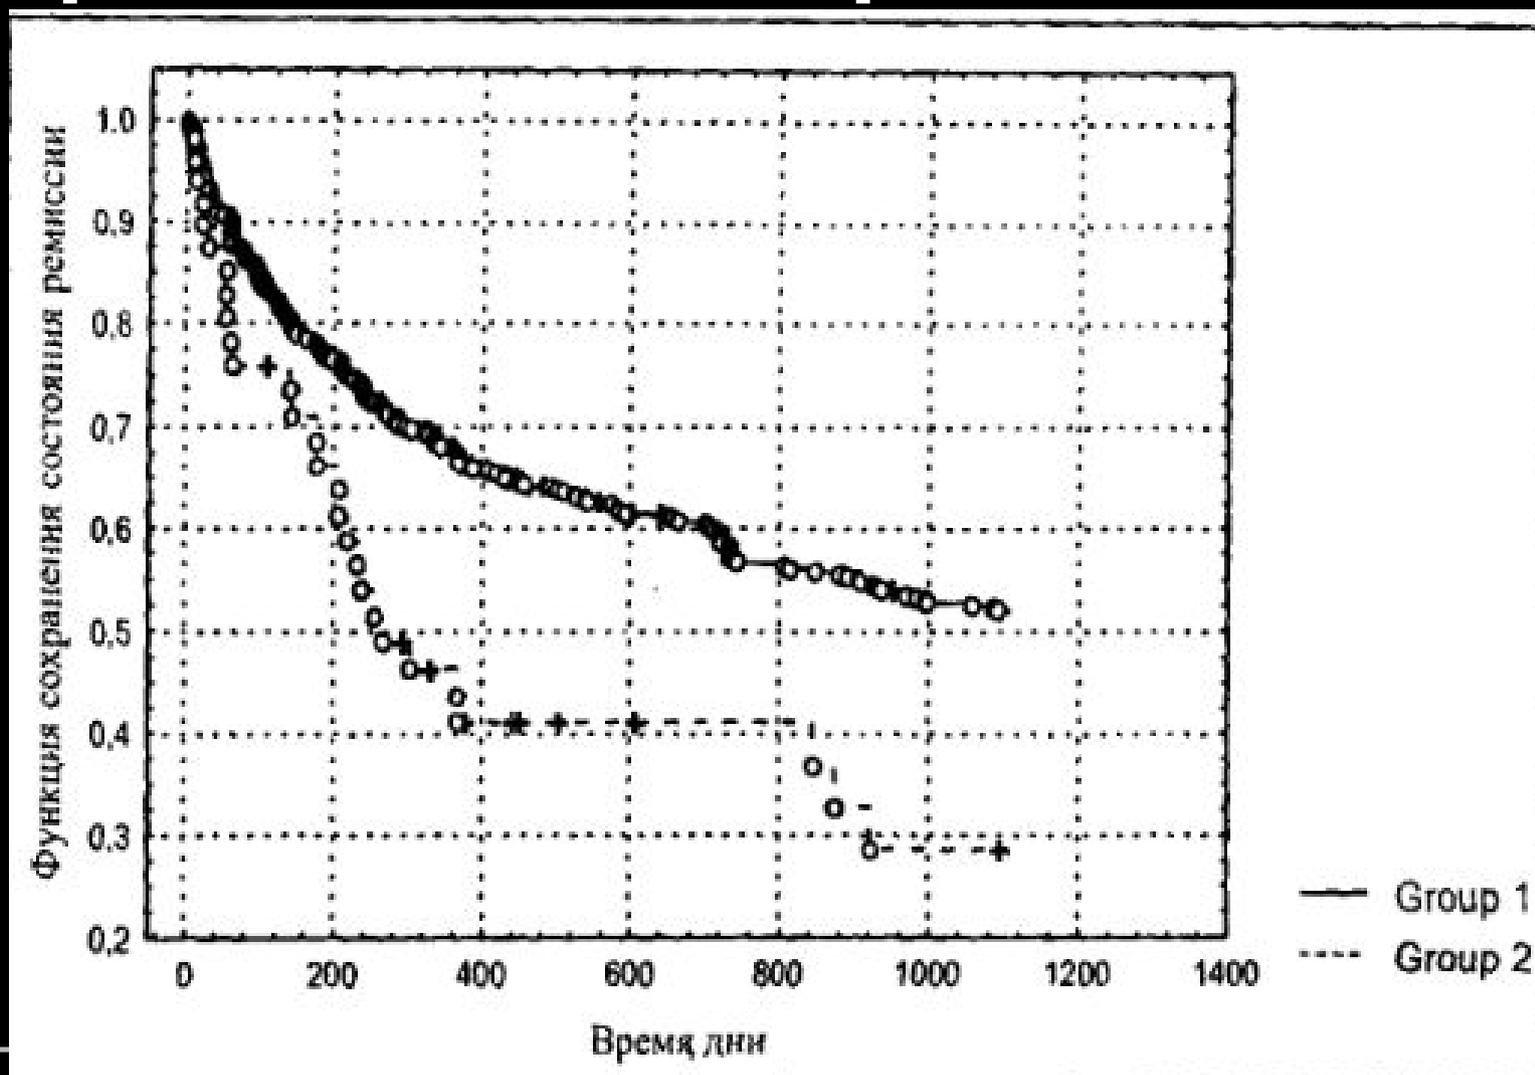
Индекс  
высокой успешности: 34.69  
средней успешности: 42.79  
низкой успешности: 40.44

# Временные ряды



Помесячное количество случаев гепатита А

# Временные ряды



Сохранность ремиссии в зависимости от вида платы за лечение

# Кластерный анализ

Кластерный анализ — метод классификации объектов по заданным признакам. Задача кластерного анализа состоит в формировании групп:

- однородных внутри (условие внутренней гомогенности);
- четко отличных друг от друга (условие внешней гетерогенности).

Техника кластерного анализа заключается в выявлении уровня схожести всех исследуемых элементов и последовательном объединении элементов в порядке возрастания уровня различия между ними. Число выявленных кластеров зависит от заданного уровня схожести (различия) элементов, включаемых в один кластер.

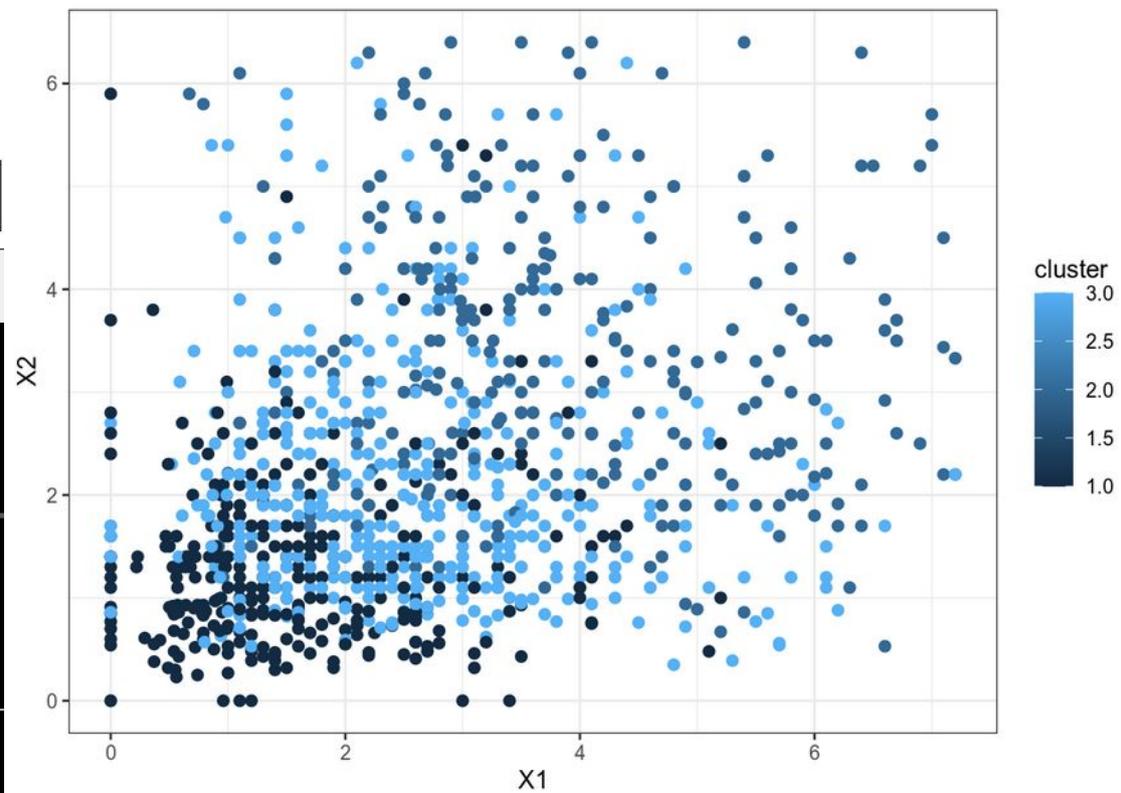
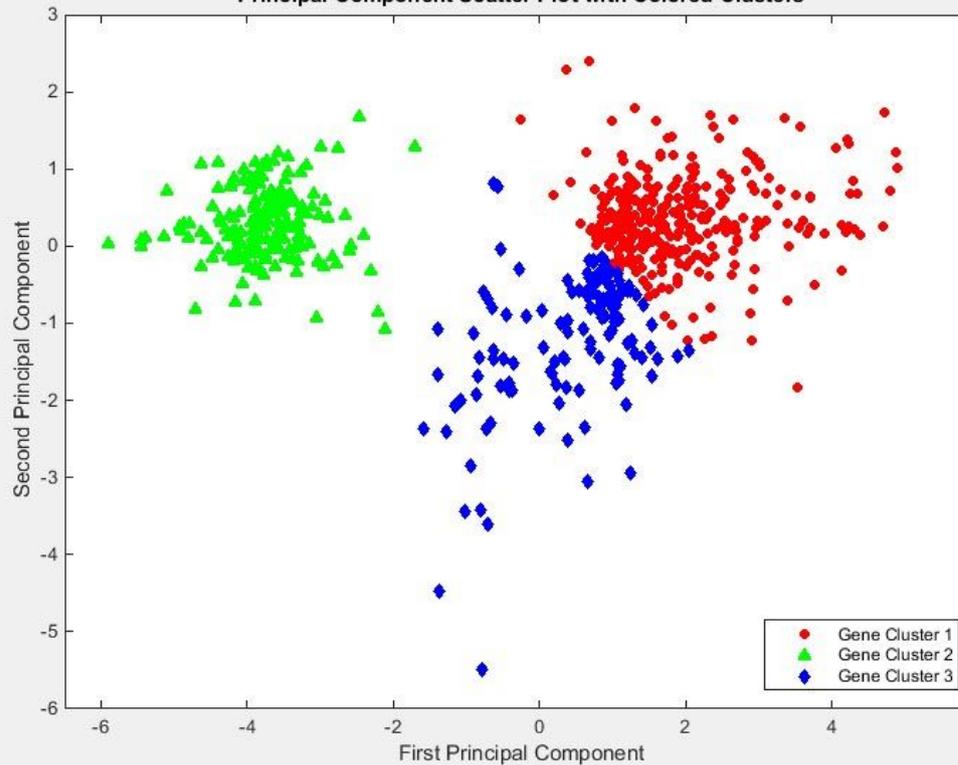
---



# Кластерный анализ

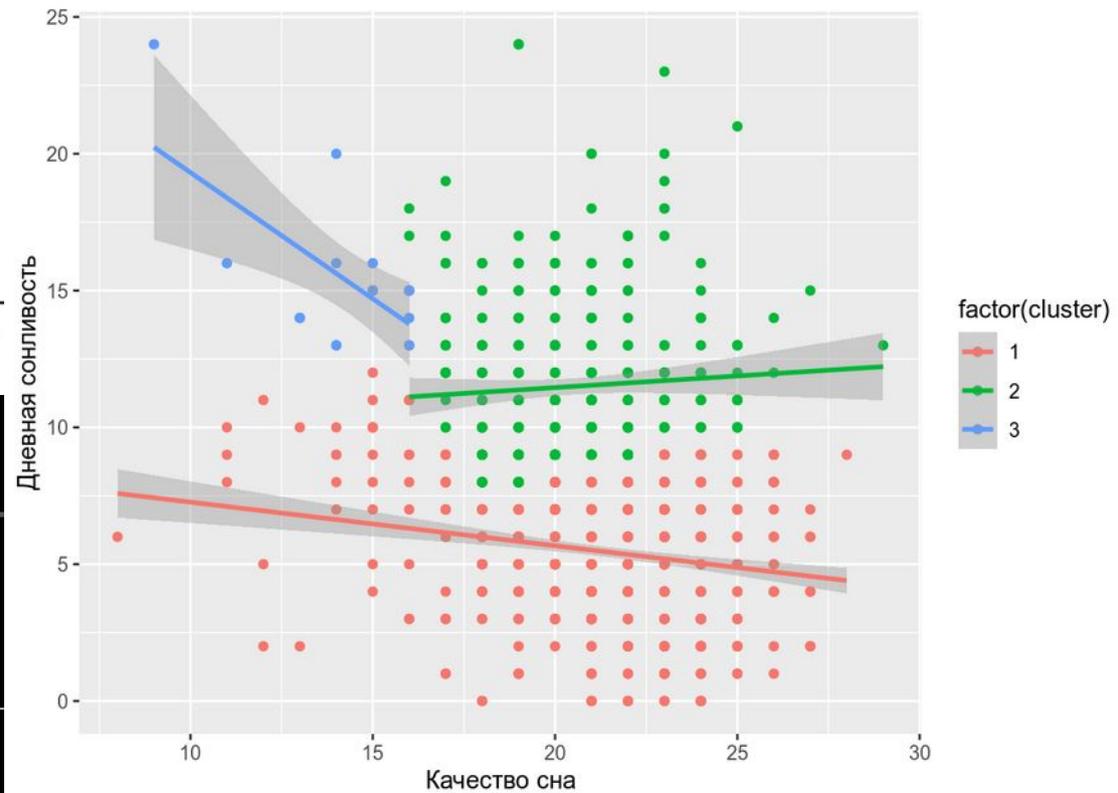
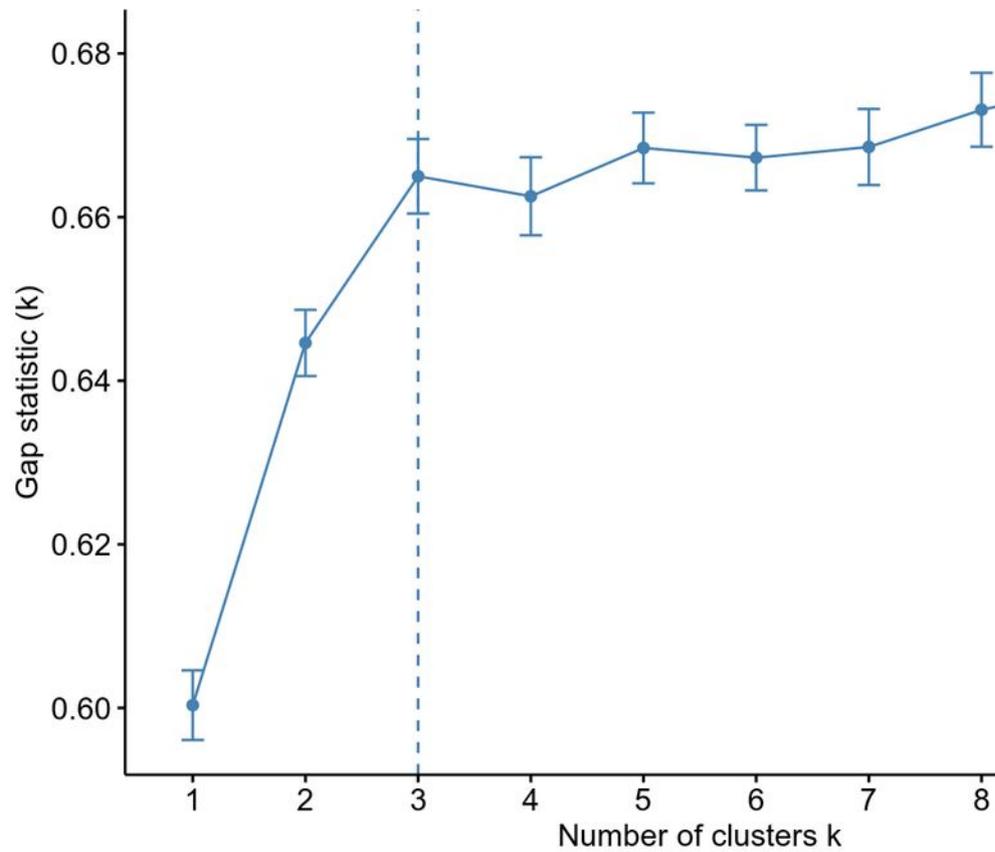
Figure 1: Cluster Analysis

Principal Component Scatter Plot with Colored Clusters

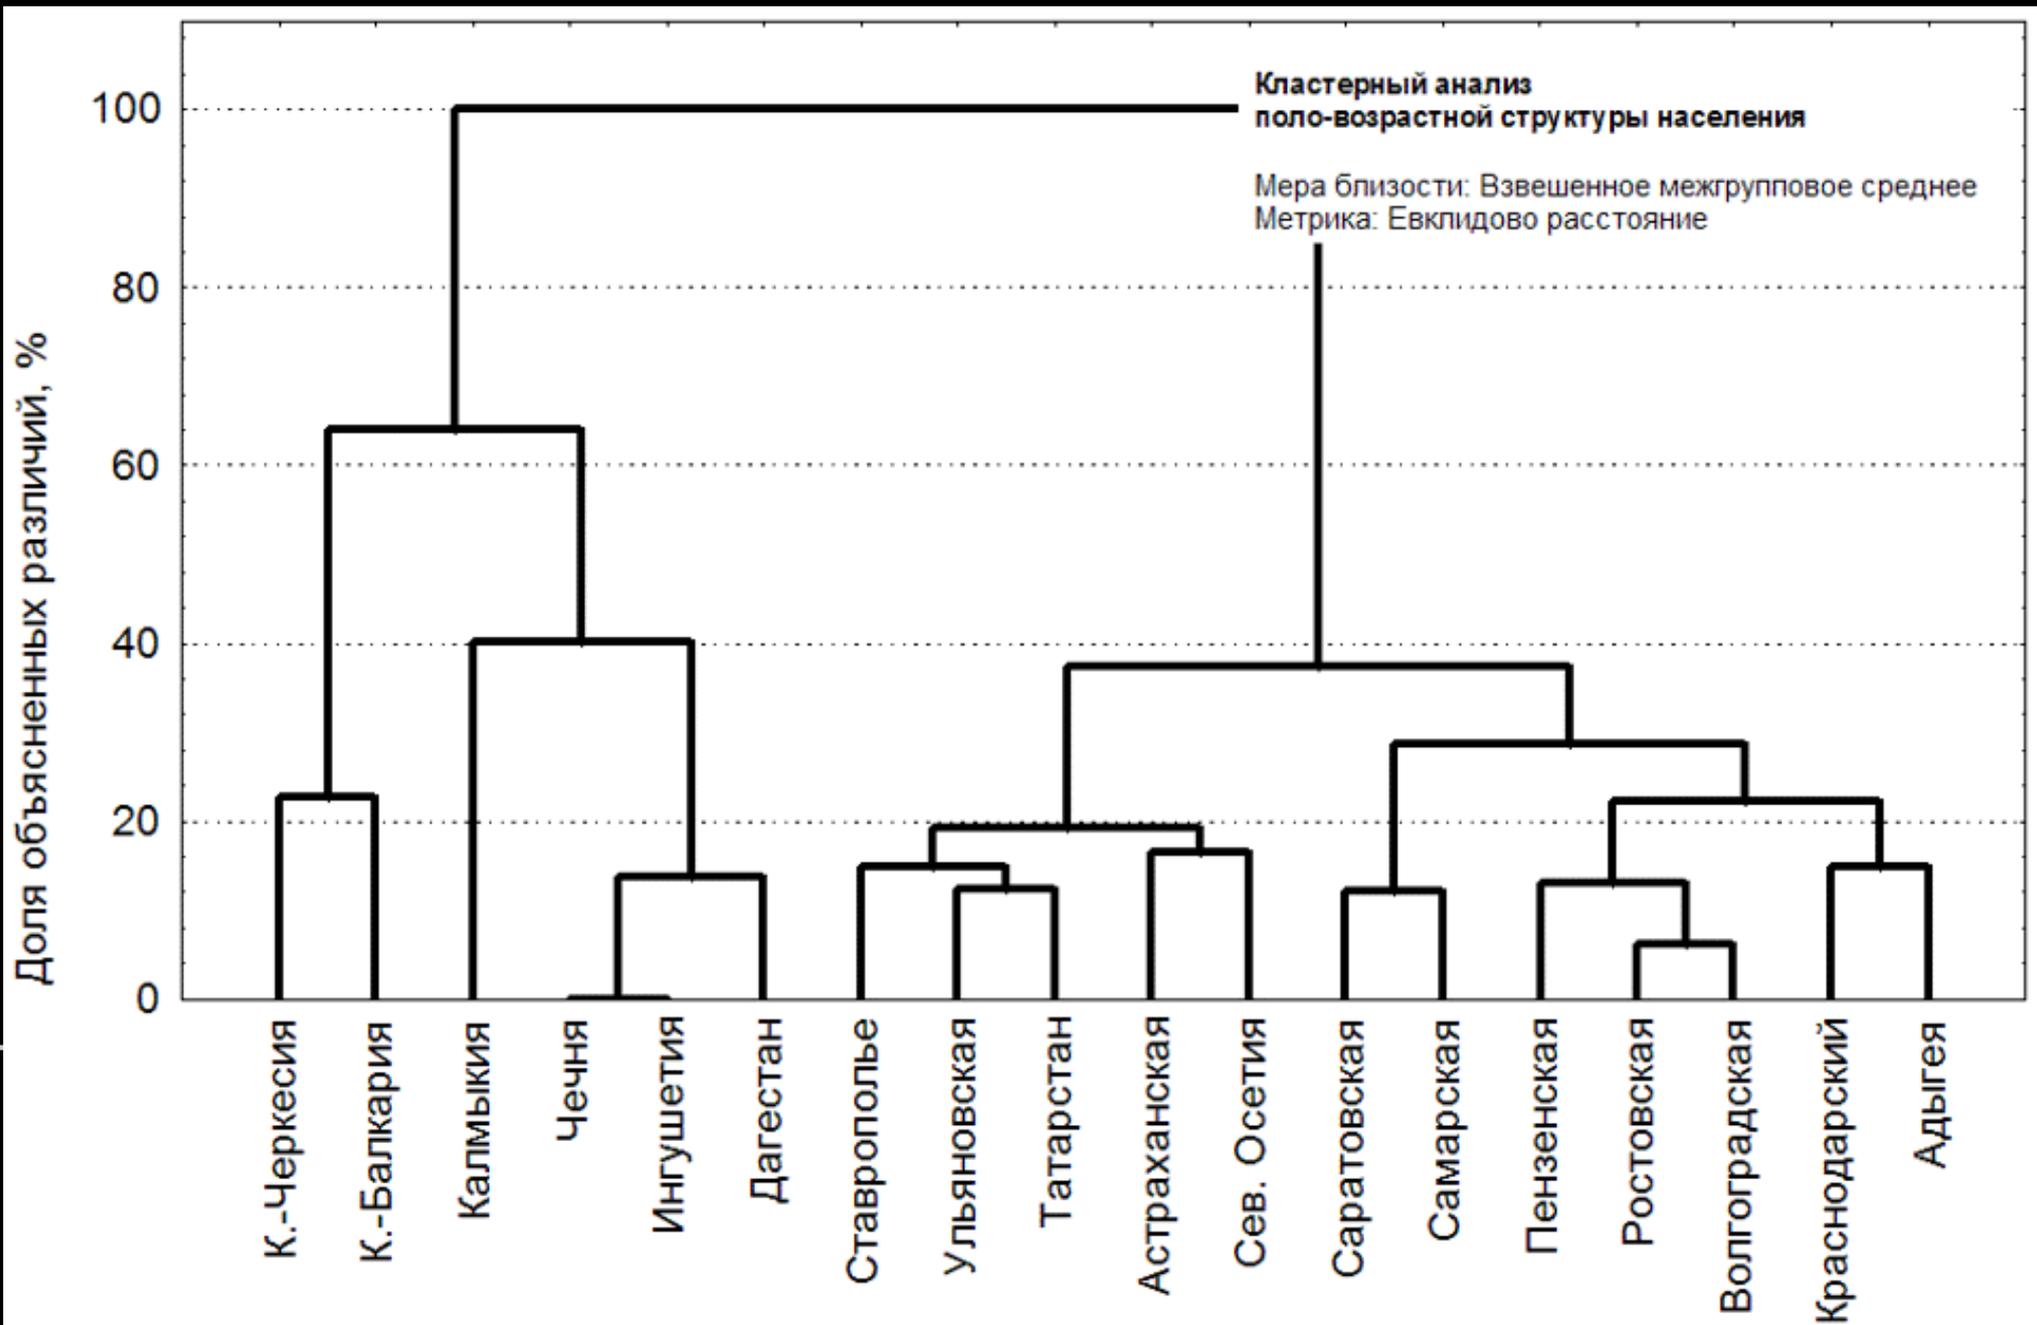


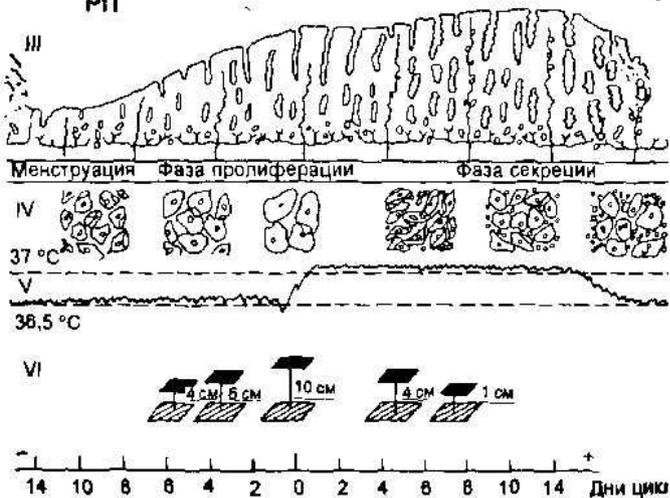
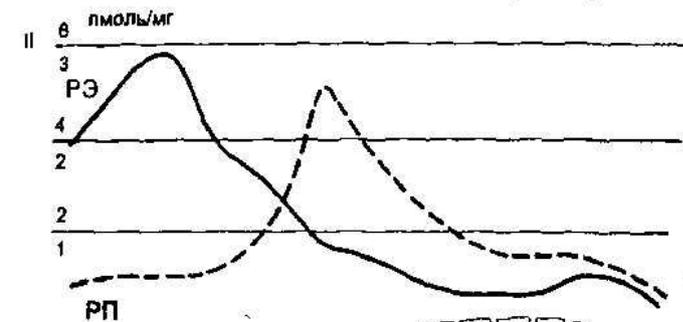
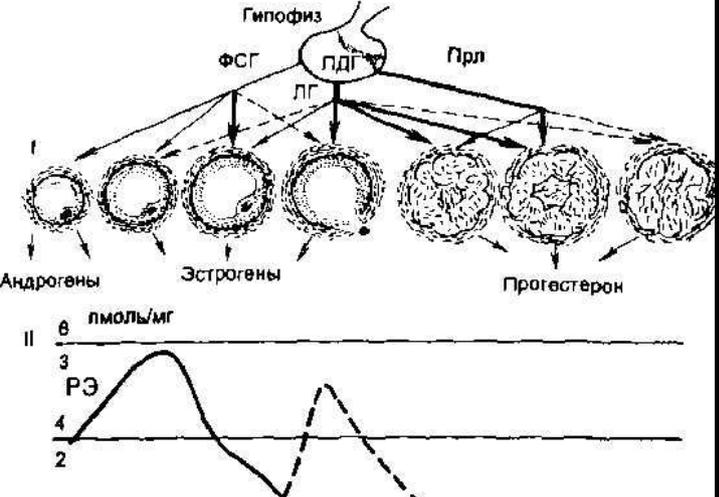
# Кластерный анализ

Optimal number of clusters

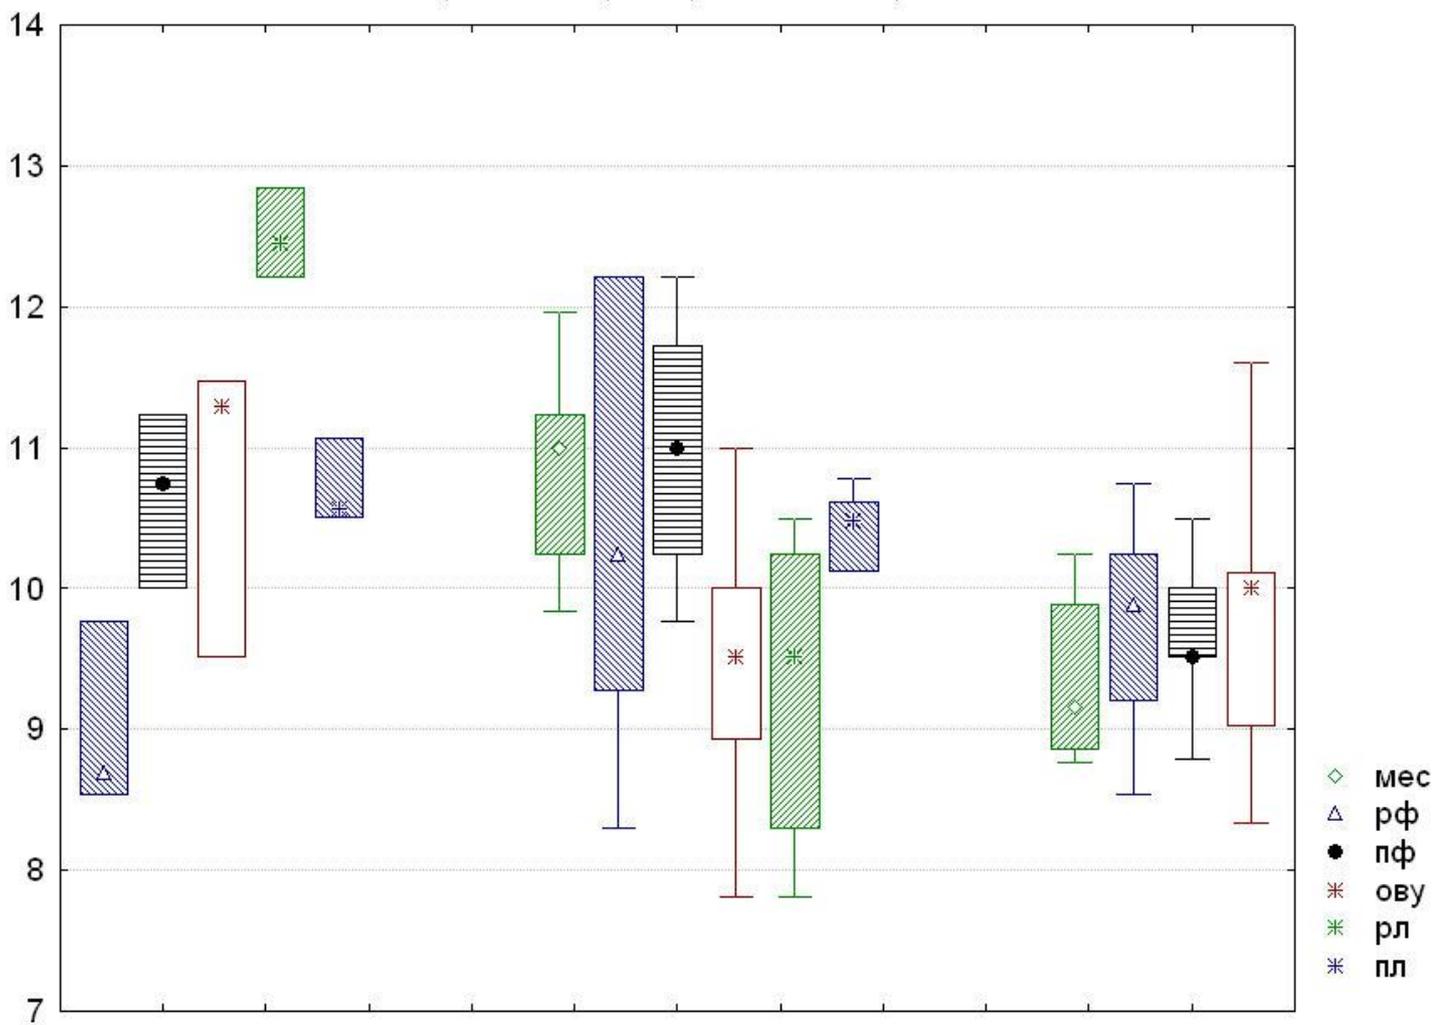


# Кластерный анализ





Median; Box: 25%, 75%; Whisker: Min, Max



- В том случае, когда нет возможности получить истинные повторности наблюдений, разработаны методы, которые формируют так называемые "псевдовыборки".
  - Методы "численного ресамплинга" {resampling} или, как их иногда называют в русскоязычной литературе, "методы по взятию повторных выборок" объединяют три разных подхода, отличающихся по алгоритму, но близких по сути: метод "складного ножа" {jackknife}, бутстреп {bootstrap} и метод перестановок {permutation}.
- 
- 

**ВОЕННО-МЕДИЦИНСКАЯ АКАДЕМИЯ**

**В.И.Юнкеров, С.Г.Григорьев**

**МАТЕМАТИКО-СТАТИСТИЧЕСКАЯ  
ОБРАБОТКА ДАННЫХ  
МЕДИЦИНСКИХ ИССЛЕДОВАНИЙ**



**Санкт-Петербург  
2002**