

**ГОСУДАРСТВЕННОЕ ОБРАЗОВАТЕЛЬНОЕ УЧРЕЖДЕНИЕ  
ВЫСШЕГО ПРОФЕССИОНАЛЬНОГО ОБРАЗОВАНИЯ  
«САМАРСКИЙ ГОСУДАРСТВЕННЫЙ АЭРОКОСМИЧЕСКИЙ  
УНИВЕРСИТЕТ имени академика С.П. КОРОЛЕВА»**

**КОРРЕЛЯЦИОННЫЙ И РЕГРЕССИОННЫЙ АНАЛИЗ  
МЕДИКО-БИОЛОГИЧЕСКИХ ДАННЫХ В СРЕДЕ  
СТАТИСТИЧЕСКОГО ПАКЕТА R**

**САМАРА 2010**

ФЕДЕРАЛЬНОЕ АГЕНТСТВО ПО ОБРАЗОВАНИЮ  
ГОСУДАРСТВЕННОЕ ОБРАЗОВАТЕЛЬНОЕ УЧРЕЖДЕНИЕ  
ВЫСШЕГО ПРОФЕССИОНАЛЬНОГО ОБРАЗОВАНИЯ  
«САМАРСКИЙ ГОСУДАРСТВЕННЫЙ АЭРОКОСМИЧЕСКИЙ  
УНИВЕРСИТЕТ имени академика С.П. КОРОЛЕВА»

КОРРЕЛЯЦИОННЫЙ И РЕГРЕССИОННЫЙ АНАЛИЗ  
МЕДИКО-БИОЛОГИЧЕСКИХ ДАННЫХ В СРЕДЕ  
СТАТИСТИЧЕСКОГО ПАКЕТА R

*Утверждено Редакционно-издательским советом университета  
в качестве методических указаний к практическим занятиям*

САМАРА  
Издательство СГАУ  
2010

УДК 612.85(075)

Составитель М.В. Комарова

Рецензент доц. В.Н. Колюхов

**Корреляционный и регрессионный анализ медико-биологических данных в среде статистического пакета R:** метод. указания к практ. занятиям / сост. *М.В. Комарова*. — Самара: Изд-во Самар. гос. аэрокосм. ун-та, 2010. — 24 с.

В методических указаниях представлены краткие сведения о корреляционном анализе, линейной и логистической регрессионных моделях. Описаны особенности их выполнения в среде статистического пакета R. Приведены примеры реальных биомедицинских данных и требования к отчёту.

Предназначены для студентов, обучающихся по специальности 200401 «Биотехнические и медицинские аппараты и системы» при изучении курса «Системный анализ и принятие решений».

Подготовлены на кафедре радиотехники и медицинских диагностических систем.

**Цель работы:** ознакомиться с проведением корреляционного и регрессионного анализов в среде статистического пакета R; построить модели линейной и логистической регрессии по массивам реальных биомедицинских данных, проанализировать полученные модели.

## РАБОТА 1. ИССЛЕДОВАНИЕ ТЕСНОТЫ ВЗАИМОСВЯЗЕЙ БИОМЕДИЦИНСКИХ ДАННЫХ В СРЕДЕ R

### КРАТКИЕ ТЕОРЕТИЧЕСКИЕ СВЕДЕНИЯ

**Корреляция моментов Пирсона.** Корреляция отражает тесноту и направленность взаимосвязи двух переменных. Если форма распределения анализируемых признаков не очень сильно отличается от нормальной и отсутствуют выбросы, рассчитывают коэффициент корреляции Пирсона (часто называемый просто коэффициентом корреляции):

$$r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}}, \quad (1.1)$$

где  $x_i$  и  $y_i$  — анализируемые показатели,  $n$  — число наблюдений.

Коэффициент корреляции изменяется в диапазоне от  $-1$  до  $+1$ . Знак его отражает направленность взаимосвязи ( $+$  прямая,  $-$  обратная), абсолютное значение — тесноту. В прикладных исследованиях часто используют следующие условные градации:

$ r  < 0,3$	связь слабая
$0,3 \leq  r  < 0,6$	связь умеренная
$0,6 \leq  r  < 0,8$	связь сильная, тесная
$0,8 \leq  r  < 1$	связь очень сильная

Следует помнить, что корреляция между величинами  $x$  и  $y$  не обязательно отражает причинно-следственные связи между ними.

**Ранговые коэффициенты корреляции.** Непараметрические, или ранговые коэффициенты корреляции Спирмена или Кендалла, рассчитывают в следующих случаях:

– форма распределения отличается от нормальной, например, скошена в ту или иную сторону;

– есть значительные выбросы (которые отражают не ошибки измерений или регистрации данных, а их реальные биологические особенности);

– шкала измерений не количественная, а порядковая;

– небольшой размер выборки.

При вычислении коэффициента корреляции *Спирмена* ( $r_s$ ) величины  $x$  сортируют по возрастанию и ранжируют. Равные величины получают средние значения из рангов, которые получили бы эти значения без ограничения. Аналогично присваивают ранги величинам  $y$ . Находят разности рангов  $x_i$  и  $y_i$ , обозначаемые  $d_i$ .

$$r_s = 1 - \frac{6 \sum_{i=1}^n d_i^2}{n(n^2 - 1)}. \quad (1.2)$$

Коэффициент корреляции *Кендалла* ( $\tau$ ) рассчитывают по следующему алгоритму:

1. Значения  $x$  ранжируют по возрастанию.
2. Значения  $y$  располагают соответственно  $x$  и ранжируют.
3. Для каждого ранга  $y_i$  определяют число следующих за ним значений рангов, больших  $y_i$ . Суммируют и получают  $n_c$  — число согласованных пар (от англ. *concordant*), или последовательностей.
4. Для каждого значения  $y_i$  определяют число следующих за ним рангов, меньших  $y_i$ . Суммируют и получают  $n_d$  — число рассогласованных пар (от англ. *discordant*), или инверсий.
5. Рассчитывают  $\tau$  по формуле:

$$\tau = \frac{2(n_c - n_d)}{n(n-1)}. \quad (1.3)$$

*Примечание:* при связанных рангах формула несколько усложняется.

**Статистическая значимость коэффициента корреляции.** Уровень статистической значимости коэффициента корреляции (Пирсона, Спирмена или Кендалла) зависит от числа наблюдений и может быть оценен с помощью следующей статистики:

$$t = \frac{r\sqrt{n-2}}{\sqrt{1-r^2}}, \quad (1.4)$$

где  $r$  — коэффициент корреляции,  $n$  — число наблюдений. Рассчитанная статистика  $t$  имеет распределение Стьюдента с  $(n-2)$  степенями свободы. При этом проверяются следующие статистические гипотезы:

$H_0$ : Корреляция между переменными не отличается от нуля.

$H_1$ : Корреляция между переменными достоверно отличается от нуля.

При уровне статистической значимости  $p < 0,05$  мы отвергаем нулевую гипотезу и считаем, что связь между изучаемыми переменными действительно существует. Следует различать понятия статистической значимости и тесноты взаимосвязей, т.е. связи могут быть слабыми и в то же время значимыми (при большом числе наблюдений) и, наоборот, умеренными или даже сильными, но не значимыми, если наблюдений недостаточно.

## **ФУНКЦИИ R ДЛЯ ПРОВЕДЕНИЯ КОРРЕЛЯЦИОННОГО АНАЛИЗА**

### **Функция `corr()`**

Для расчета коэффициентов корреляции применяют функцию:

`corr(x, use=, method=)`.

Функция возвращает матрицу корреляций между указанными переменными.

### **Аргументы**

**x** — набор данных, между которыми вычисляются корреляции (можно указать имена переменных рабочего файла в кавычках);

**use** — обработка пропусков. Возможные значения:

`all.obs` — без пропусков (пропущенные данные вызовут ошибку);

`complete.obs` — построчная обработка пропусков;

`pairwise.complete.obs` — попарная обработка пропусков;

**method** — вид корреляции. Возможные значения:

`pearson` — корреляция Пирсона;

`spearman` — корреляция Спирмена;

`kendall` — корреляция Кендалла.

### Функция `corr.test()`

Для оценки уровня значимости коэффициентов корреляции применяют функцию:

```
corr.test(x, y, alternative=, method=).
```

#### *Аргументы*

**x, y** — набор данных, должны быть одинаковой длины;

**alternative** — альтернативная гипотеза (двусторонний или односторонний тест). Возможные значения:

`two.sided`;

`greater`;

`less`;

**method** — вид тестируемой корреляции. Возможные значения:

`pearson` — корреляция Пирсона;

`spearman` — корреляция Спирмена;

`kendall` — корреляция Кендалла.

### ФУНКЦИИ R ДЛЯ ГРАФИЧЕСКОЙ ИНТЕРПРЕТАЦИИ КОРРЕЛЯЦИОННОГО АНАЛИЗА

Для визуального исследования зависимости между двумя переменными используют двумерные диаграммы рассеяния, или графики разброса.

#### Функция `scatterplot()`

Для создания графика разброса между двумя переменными применяют функцию:

```
scatterplot(formula, data, xlab, ylab, legend.title,  
ellipse, reg.line, smooth).
```

#### *Аргументы*

**formula** — «формула» для построения графика, применяют в форме  $y \sim x$  или  $y \sim x | z$ , где  $z$  — фактор, подразделяющий выборку на подгруппы;

**data** — массив данных, по которому строится график разброса;

**xlab** — название горизонтальной оси;

**ylab** — название вертикальной оси;

**legend.title** — заголовок легенды;

**ellipse** — при значении TRUE вместо точек на графике отображаются корреляционные эллипсы;

**reg.line** — отображает линию линейной регрессии при значении TRUE и не отображает её при значении FALSE;

**smooth** — отображает кривую нелинейной регрессии при значении TRUE и не отображает её при значении FALSE.

При необходимости построить матрицу парных графиков по нескольким переменным можно воспользоваться функцией:

```
scatterplot.matrix ()
```

Аргументы данной функции во многом аналогичны таковым функции `scatterplot()`, иначе пишется «формула» графика:  $\sim x_1 + x_2 + x_3 \dots$ . Помимо указанных функций, код которых генерирует оболочка R commander, существует функция `pairs()`, которая также создаёт графики разброса.

Пример матрицы парных графиков гематологических показателей приведён на рис. 1. По диагонали представлены имена анализируемых переменных (гематологических показателей в нашем примере). Каждая точка отражает одно наблюдение, её координаты определяются значениями двух переменных. Выше и ниже диагонали с именами переменных расположены одни и те же пары переменных, но по разным осям. Например, график в первой строке и втором столбце отражает зависимость НСТ1 (гематокрит, ось ординат) от HGB1 (гемоглобин, ось абсцисс), а график во второй строке, первом столбце — наоборот зависимость HGB1 от НСТ1.

Если переменные тесно и линейно связаны, то множество точек данных принимает форму узкого эллипса или почти прямой. В рассматриваемом примере между HGB1 и НСТ1 — очень тесная связь; между HGB1 и МСН1 — умеренная по тесноте связь. Если переменные не связаны, то точки образуют облако рассеяния (МСН1 и МСНС1).

Диаграммы рассеяния предоставляют исследователю больше информации, чем простое значение коэффициента корреляции. Они позволяют:

- выявить отсутствие однородности в выборке (например, наличие подгрупп с разным характером взаимосвязи);
- найти выбросы, или нетипичные данные, которые искусственным образом могут значительно увеличить или уменьшить коэффициент корреляции Пирсона;
- обнаружить нелинейный характер взаимосвязи.

Таким образом, перед проведением корреляционного анализа желательно анализировать графики разброса, с помощью которых можно подобрать оптимальный срез данных для исследования (т.е. выделить определённые подгруппы или, наоборот, объединить разные подгруппы в одну, исключить выскакивающие наблюдения) и применить подходящий вид корреляции (Пирсона или его непараметрических аналогов — Спирмена или Кендалла).

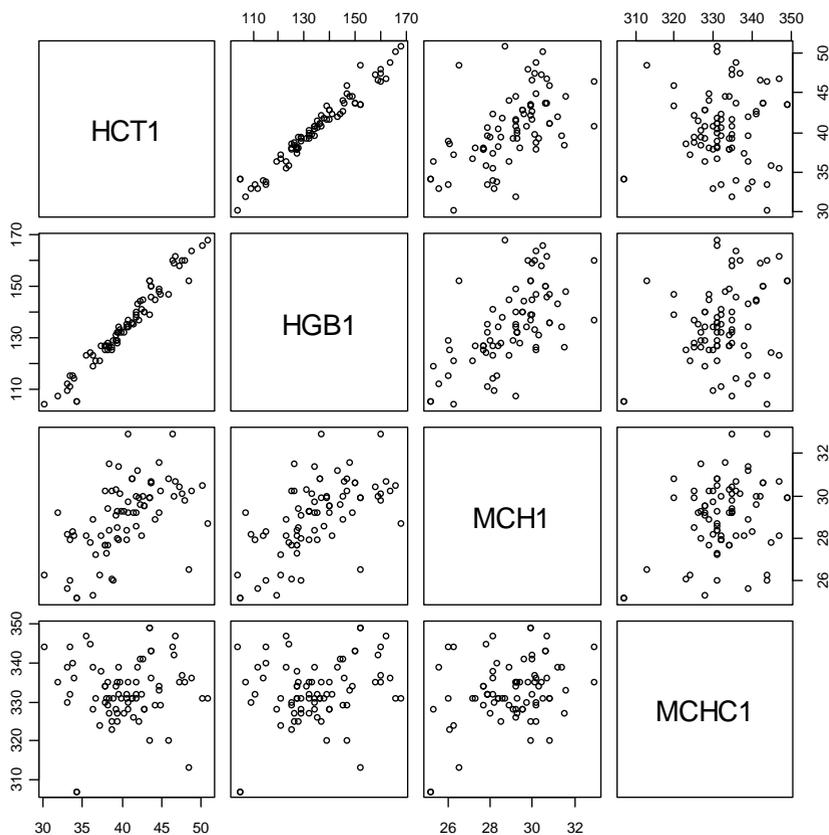


Рис. 1 — Диаграммы рассеяния биологических показателей в зависимости от тесноты взаимосвязи

## ПОРЯДОК РАБОТЫ

1. Запустите пакет R с помощью файла: R-2.7.2/bin/Rgui.exe. В окне R Console напишите: `library(Rcmdr)`. Дальнейшая работа проходит в данной графической оболочке, которая генерирует необходимый код

через кнопочный интерфейс. Для загрузки данных в графической оболочке R commander выбрать следующие пункты меню:

Данные

Импорт данных

Из файла SPSS

*Появится новое диалоговое окно. Со всем согласиться, нажать ОК.*

*Найти файл pregn.sav.*

2. Исследуйте взаимосвязи клинико-лабораторных данных новорождённых и их матерей. Для этого воспользуйтесь корреляционным анализом:

Статистики

Итоги

Корреляционная матрица

*В появившемся диалоговом окне укажите исследуемые переменные (выбрать один вариант):*

### **Вариант 1**

p\_ch1 — масса ребёнка

len\_ch1 — длина ребёнка

week — гестационный срок (в неделях)

tromb — тромбоциты матери

svet — свёртываемость крови матери

### **Вариант 2**

h1 — рост матери

p\_0 — масса матери

age — возраст матери

imt — индекс массы тела матери

p\_len — соотношение массы и длины ребёнка

### **Вариант 3**

Hb2 — гемоглобин матери

er2 — эритроциты матери

tp1 — общий белок матери

p\_0 — масса матери 1

p\_2 — масса матери 2

Выберите вначале корреляцию Пирсона, потом Спирмена. Проанализируйте полученную матрицу корреляций. Какие связи сильные, какие слабые, а какие умеренные? Для нескольких пар показателей найдите уровень значимости коэффициента корреляции.

Статистики

Итоги

Корреляционный тест

3. Проиллюстрируйте полученные результаты (для этих же переменных) на графиках разброса:

Графики

Матрица точечных графиков

*Выбрать необходимые переменные.*

*Убрать галочки с «линии наименьших квадратов» и «сгладить линии».*

*В отчёт:* по заданию 1 и 2 выберите 3 графика разброса. Укажите численное значение коэффициентов корреляции и их уровней значимости. Дайте содержательную оценку взаимосвязей: прямая или обратная, слабая или сильная. Какие значения коэффициентов корреляции больше по абсолютному значению: Пирсона или Спирмена?

4. Проведите исследование взаимосвязей в различных подгруппах обследованных. Постройте ещё раз графики разброса, нажав на кнопку «графики по группам» и введя качественный признак gestoz. Теперь на графиках разным цветом и разными маркёрами выделены наблюдения (пациенты) из различных групп по степени тяжести осложнения беременности — гестозу. Что можно увидеть, глядя на полученные графики? Различаются ли взаимосвязи в разных подгруппах?

## **РАБОТА 2. ПАРНАЯ ЛИНЕЙНАЯ РЕГРЕССИЯ**

### **КРАТКИЕ ТЕОРЕТИЧЕСКИЕ СВЕДЕНИЯ**

Регрессионный анализ решает следующие задачи:

- восстановление зависимости между исследуемыми переменными;
- прогноз зависимой переменной (переменной отклика) по известным независимым переменным (предикторам).

Регрессия бывает:

- по числу предикторов — парная и множественная;
- по форме зависимости — линейная и криволинейная.

Исходные данные для регрессионного анализа представляют собой таблицу (матрицу), в которой строки соответствуют объектам (испытуемым), а столбцы — переменным. Все переменные при этом должны быть измерены в количественной шкале. Одна из переменных определяется исследователем как зависимая, а остальные как независимые переменные.

Парная линейная регрессия в общем случае имеет вид:  $y=b_0+b_1x$ . Нахождение коэффициентов регрессии основано на методе наименьших квадратов (минимизация суммы квадратов отклонений эмпирических значений признака от теоретических, полученных по уравнению регрессии).

## ФУНКЦИИ R ДЛЯ ПОСТРОЕНИЯ ЛИНЕЙНОЙ РЕГРЕССИИ

Для построения линейной регрессии в пакете R можно воспользоваться функцией `lm()`:

```
lm(formula, data, subset, weights, na.action).
```

### *Аргументы*

**formula** — символическое описание восстанавливаемой модели. Для парной линейной регрессии имеет вид  $y\sim x$ , для множественной —  $y\sim x_1+x_2+x_3\dots$ ;

**data** — источник данных;

**subset** — подмножество данных, участвующих в построении модели, необязательный параметр;

**weights** — вектор весов, может быть или NULL, или числовым;

**na.action** — обработка пропущенных данных (NA).

### *Трактовка результатов*

Объект, возвращаемый функцией `lm`, имеет различные поля:

**Residuals** — остатки ( $y_i - bx_i$ ), распределение по квартилям.

**Coefficients** — коэффициенты регрессии и их статистическая значимость:

**Estimate** — коэффициент регрессии  $b$ ;

**Std. Error** — ошибка коэффициента регрессии  $b$ ;

**t value** — статистика  $t$  для оценки уровня значимости коэффициента регрессии;

**Pr(>|t|)** — достигнутый уровень значимости коэффициента регрессии.

**Multiple R-squared** — коэффициент детерминации модели.

**Adjusted R-squared** — скорректированный коэффициент детерминации модели.

**F-statistic** — F-статистика для модели в целом.

**p-value** — уровень значимости модели в целом.

## ПОРЯДОК РАБОТЫ

1. Постройте уравнение зависимости веса и длины новорождённых от гестационного срока родов (в неделях, переменная week). Для этого выберите следующие пункты меню в оболочке R commander:

Статистики  
Подгонка моделей  
Линейная регрессия

В появившемся диалоговом окне укажите: зависимая переменная — p\_ch1 (или len\_ch1), независимая — week. Проанализируйте график остатков (наблюдаемое минус предсказанное регрессионной моделью значение). Одинаковы ли они на всём диапазоне значений предсказывающей переменной.

Модели  
Графики  
График Компонента + остаток

**Отразить в отчёте.** По таблице коэффициентов запишите полученное уравнение регрессии. Значимы ли коэффициенты регрессии? В каком диапазоне значений данное уравнение будет хорошо работать?

2. Для двух произвольных выборок ( $n_1=n_2=10$ ) восстановите парную линейную регрессию в среде Excel. Рассмотрите два варианта зависимости:  $y(x)$  и  $x(y)$ .

Коэффициенты регрессии можно найти по формулам:

$$b_1 = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2}, \quad (2.1)$$

$$b_0 = \bar{y} - b_1 \bar{x}. \quad (2.2)$$

Рассчитайте также коэффициент корреляции Пирсона между выборками (по формуле 1.1) или его модуль по формуле:

$$y = \pm \sqrt{b_{1x(y)} b_{1y(x)}}. \quad (2.3)$$

Отразите графически обе зависимости  $y(x)$  и  $x(y)$ . Примерный вид графиков приведён на рис. 2.

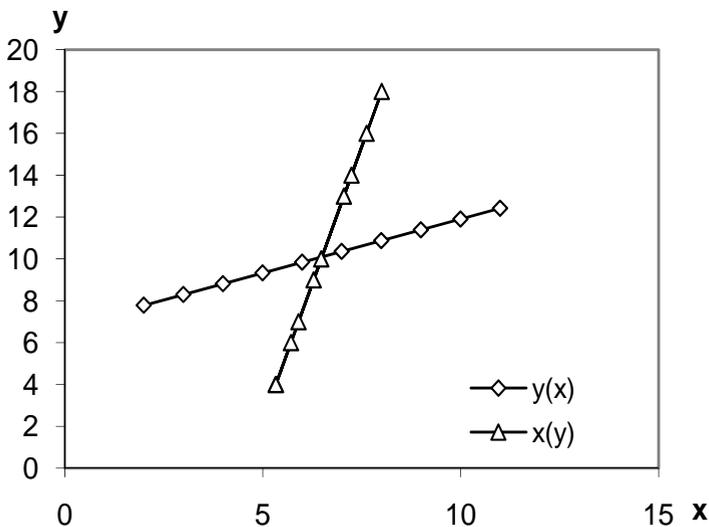


Рис. 2 — Парная линейная регрессия

После построения двух графиков изменять исходные данные так, чтобы получались различные коэффициенты корреляции. Как меняется расположение графиков и угол между прямыми? В какой точке пересекаются прямые?

### РАБОТА 3. МНОЖЕСТВЕННАЯ ЛИНЕЙНАЯ РЕГРЕССИЯ: ПОШАГОВОЕ ПОСТРОЕНИЕ

#### КРАТКИЕ ТЕОРЕТИЧЕСКИЕ СВЕДЕНИЯ

Множественная линейная регрессия позволяет изучить совместное воздействие нескольких независимых переменных на переменную отклика. Практическое применение двоякое: для предсказания переменной отклика и для определения интенсивности, с которой каждая независимая переменная линейно связана с зависимой. В общем случае уравнение множественной линейной регрессии имеет вид:

$$y = b_0 + b_1x_1 + b_2x_2 \dots + b_kx_k . \quad (3.1)$$

Интерпретация коэффициентов регрессии та же, что и в парной регрессии — на сколько изменится переменная отклика при увеличении предиктора на единицу.

## ВЫПОЛНЕНИЕ РАБОТЫ

**Цель работы:** изучение пошаговых методов построения множественной линейной регрессии; диагностика полученной модели; работа с частью массива данных.

### Порядок работы

1. Запустите R; выполните команду: `library(Rcmdr)`. Загрузите файл `food.xls`. Обратите внимание, что файл имеет расширение `xls`, следовательно, нужен экспорт из Excel. Выбрать первый лист.

В данном массиве приведены некоторые антропометрические данные здоровых мужчин и женщин, их возраст, а также рассчитанные на основе анкетирования съедаемые калории, жиры, углеводы, микроэлементы. Задача исследования: выявить компоненты пищи, от которых в первую очередь зависит индекс массы тела.

Для построения регрессионной модели отдельно для мужчин и женщин необходимо выбрать подмножество данных. В R консоли или окне скриптов напишите и выполните команду:

```
data_m <- subset(data1, Пол==1).
```

### Обозначения

- `data_m` — имя нового набора данных, оно может быть произвольным;
- `subset` — команда R, выбирающая часть массива данных согласно определённому условию;
- `data` — имя исходного набора данных (если при открытии файла было присвоено по умолчанию имя Данные, то его и надо писать);
- `Пол==1` — условие, по которому осуществляется выбор. В анализируемом массиве мужчины обозначены кодом 1, женщины 2. Если бы мы работали с качественным признаком, имеющим не числовой, а строковый формат, то значение нужно было бы взять в кавычки.

Теперь необходимо сделать полученный массив данных активным. Для этого выполните пункты меню R commander:

Данные

Активные данные

Выбрать активный набор данных

*В появившемся диалоговом окне выберите необходимый набор данных.*

Просмотрите массив данных (из режима просмотра удобно скопировать имена переменных для построения дальнейшей модели).

2. Для построения пошаговой множественной линейной регрессии выполните следующие команды:

Команда	Описание
<code>library(MASS)</code>	Вызов модуля MASS для пошагового построения регрессии
<code>fit1 &lt;- lm(y~x1+x2+x3, data=mydata) fit1</code>	Построение модели множественной линейной регрессии методом включения всех предикторов в общем виде: имя создаваемой модели, к которому можно будет в дальнейшем обратиться для вывода различных характеристик построенной модели;
<code>y</code>	зависимая переменная (в нашем задании — ИМТ, или окружность талии или бёдер);
<code>x1+x2+x3</code>	переменные отклика (включить возраст и всё-всё, связанное с пищей: белки, различные жиры, углеводы, микроэлементы);
<code>mydata</code>	имя массива данных, на котором строится модель (например, <code>data_m</code> или <code>data_f</code> для мужчин и женщин соответственно)
<code>summary(fit1) fit1</code>	описание полученной модели: имя модели, заданное при её построении
<code>fit1_step &lt;- stepAIC(fit1, direction="backward") fit1_step</code>	построение новой модели с пошаговым исключением предикторов: имя новой, создаваемой пошаговым методом модели;
<code>fit1</code>	имя первоначальной модели, в которой присутствовали все предикторы
<code>summary(fit1_step)</code>	описание полученной модели (с меньшим числом предикторов)
<code>vif(fit1_step)</code>	оценка мультиколлинеарности предикторов по показателю <code>vif</code>

VIF — аббревиатура от *variance inflation factor* — величина отражающая мультиколлинеарность, т.е. тесную корреляцию предикторов друг с другом.

$$VIF = \frac{1}{1 - R_{1.all\_pred}^2}, \quad (3.2)$$

где  $R_{1.all\_pred}$  — коэффициент множественной корреляции данного предиктора со всеми остальным предикторами. Значение VIF более 2 характеризует модель как мультиколлинеарную, крайне неустойчивую к небольшим изменениям предикторов и непригодную для прогноза.

### Пример вывода результатов множественной линейной регрессии в пакете R

```

Coefficients:
              Estimate      Std. Err      t value Pr(>|t|)
(Intercept)  21.196479      1.229588      17.239 <2e-16 ***
Крахмал      0.003406      0.004069       0.837  0.40315
Общий. жир   0.029431      0.008472       3.474  0.00058***
---
Signif. codes: 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

Residual standard error: 3.636 on 337 degrees of freedom
Multiple R-squared:  0.036, Adjusted R-squared:  0.03028
F-statistic: 6.293 on 2 and 337 DF, p-value: 0.002073

```

#### Обозначения

- Первый столбец (без заголовка) — свободный член (intercept) и предикторы в модели;
- Estimate — коэффициент регрессии;
- Std. Error — стандартная ошибка коэффициента регрессии;
- t value — t-статистика, с помощью которой проверяют статистическую гипотезу отличия коэффициента регрессии от 0;
- Pr(>|t|) — уровень значимости предиктора, статистически значимые предикторы помечены звёздочками;
- Residual standard error — остаточная стандартная ошибка — показатель разброса возможных значений случайной ошибки;
- Multiple R-squared — коэффициент детерминации, или квадрат коэффициента множественной корреляции модели;
- Adjusted R-squared — скорректированный коэффициент детерминации;
- F-statistic — F-статистика, оценивающая значимость полученной модели множественной линейной регрессии в целом, и её уровень значимости.

Сравните коэффициенты регрессии до пошагового отбора и после него. Одинаковы они или нет?

Если в модели оказались незначимые или тесно коррелированные предикторы (с показателем  $vif > 2$ ), модель перестроить, исключив их из построения. Может потребоваться несколько итераций, пока не получится приемлемый результат.

Постройте диагностические графики остатков (остаток — разность между наблюдаемым и рассчитанным значением переменной отклика) регрессии. Для этого необходимо выполнить следующие команды.

#### **Команда**

```
layout(matrix(c(1, 2, 3, 4), 2, 2))
```

```
plot(fit)
```

#### **Описание**

Подготовка для построения диагностических графиков  
Построение диагностических графиков регрессии (в скобках указать имя анализируемой модели)

Примеры получаемых графиков представлены на рис. 3. График *Residuals vs Fitted* (остатки против рассчитанных значений) в хорошей модели должен быть равномерным на всем диапазоне значений переменной отклика. Аналогично трактуют график *Scale-Location*. Более точно определить закон распределения остатков можно по графику *Normal Q-Q* (график на вероятностной бумаге). Если стандартизованные остатки (откладываемые по оси ординат) нормально распределены, то все значения легли бы на прямую линию на графике; если есть выбросы или остатки распределены не по нормальному закону, то линейность графика на вероятностной бумаге нарушается. Последний график *Residuals vs Leverage* позволяет эффективно выявить выбросы, наиболее значительно влияющие на расчет коэффициентов регрессии. На всех графиках указаны номера «выскакивающих» наблюдений.

#### **Отprite в отчёте ответы на следующие вопросы**

- Все ли предикторы в модели статистически значимы?
- Есть ли в модели предикторы, для которых VIF больше 2? Если да, то сравните коэффициенты корреляции между переменной отклика и данным предиктором и коэффициентом регрессии: одинаковы ли они по знаку?
- Чему равен коэффициент детерминации модели (посмотреть на значение Adjusted R-squared)?
- Значима ли модель в целом (посмотреть на значение F-statistic и его уровень значимости — p-value)?

– Равномерно ли распределены остатки (residuals) по рассчитанным значениям переменной отклика?

3. Постройте аналогичные модели для женщин. Одинаковы ли пищевые факторы риска ожирения у разных полов?

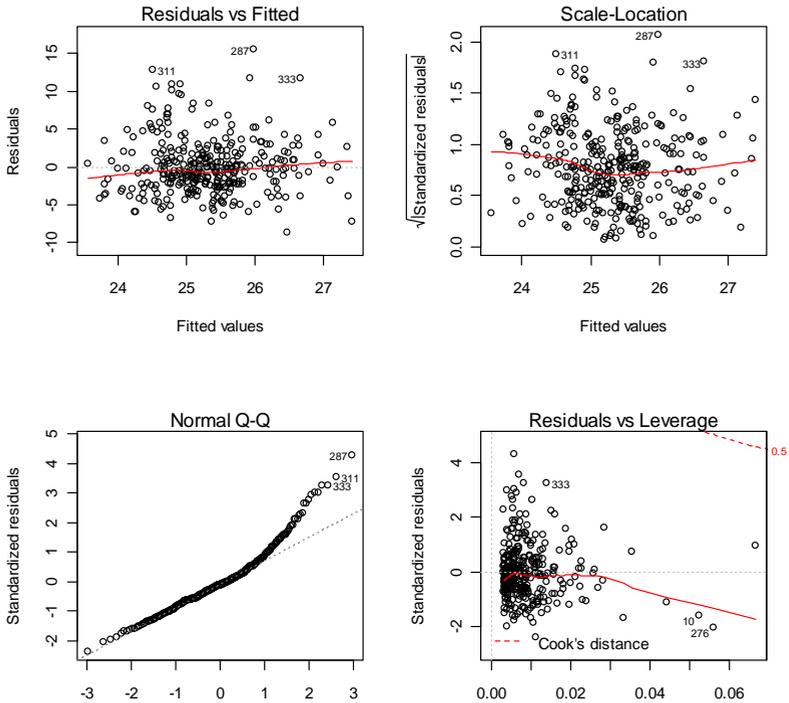


Рис. 3 — Диагностические графики в моделях множественной линейной регрессии

## РАБОТА 4. ЛОГИСТИЧЕСКАЯ РЕГРЕССИЯ

### КРАТКИЕ ТЕОРЕТИЧЕСКИЕ СВЕДЕНИЯ

Логистическая регрессия применяется для предсказания показателя с бинарным откликом (то есть имеющим два значения, в медицинских задачах это часто наличие или отсутствие заболевания) и одной или несколькими объясняющими переменными.

Модель логистической регрессии имеет вид:

$$\ln \frac{p}{1-p} = b_0 + b_1 x_1 + \dots + b_k x_k, \quad (4.1)$$

где  $p$  — вероятность моделируемого события (исхода; заболевания);  $b_0, b_1 \dots b_k$  — коэффициенты регрессии;  $x_1, x_2 \dots x_k$  — объясняющие переменные.

Тогда шансы исхода (заболевания) равны:

$$\text{шансы} = \frac{p}{1-p} = \exp(b_0 + b_1 x_1 + \dots + b_k x_k). \quad (4.2)$$

Вероятность развития исхода можно вычислить:

$$p = \frac{\text{шансы}}{1 + \text{шансы}}. \quad (4.3)$$

Интерпретация коэффициентов логистической регрессии отличается от интерпретации коэффициентов линейной регрессии. Практическое значение имеют экспоненциальные коэффициенты регрессии: они показывают, во сколько раз изменятся шансы предсказываемого состояния при повышении уровня предиктора на 1.

## ВЫПОЛНЕНИЕ РАБОТЫ

**Цель работы:** исследовать модель логистической регрессии для предсказания событий с двумя исходами.

### Ход работы

1. Запустите R с помощью файла: R-2.7.2/bin/Rgui.exe. В окне R Console напишите: `library(Rcmdr)`. Для загрузки данных в графической оболочке R commander выбрать следующие пункты меню:

Данные

Импорт данных

Из файла SPSS

*Появится новое диалоговое окно. Со всем согласиться, нажать ОК.*

*Найти файл cancer.sav.*

### Варианты заданий

#### Вариант 1

Зависимая переменная `ds1` — диагноз (1 — не рак; 2 — рак)

Независимые предикторы:

- PSA — простатоспецифический антиген, лабораторный маркер рака предстательной железы;
- CD16 — иммунологический показатель, отражающий долю лимфоцитов — так называемых натуральных киллеров, участвующих в уничтожении раковых клеток.

## Вариант 2

Зависимая переменная `ds1` — диагноз (1 — не рак; 2 — рак)

Независимые предикторы:

- `PSA_free` — свободная фракция просатоспецифического антигена, лабораторного маркера рака предстательной железы;
- `testost` — тестостерон, мужской половой гормон.

## Вариант 3

Зависимая переменная `ds1` — диагноз (1 — не рак; 2 — рак)

Независимые предикторы:

- `ro_psa` — плотность просатоспецифического антигена;
- `v` — объём простаты (по данным УЗИ).

2. Построение модели логистической регрессии можно осуществить как с помощью оболочки `R commander`, так и непосредственным введением команд. При построении первым способом в окне `R commander` выбираем следующие пункты меню:

Статистики

Подгонка моделей

Обобщенная линейная модель

Имя модели: `mylogit1` (можно и другое, можно и имеющееся по умолчанию оставить, но тогда внести коррективу в следующем задании). Первой выбираем бинарную переменную отклика; потом две независимых переменных. Семейство: `binomial`, функция связи: `logit` (они стоят по умолчанию).

То же самое можно получить, выполнив непосредственно команды в окне `R console` или в окне скриптов `R commander`:

Команда	Описание
<pre>mylogit1 &lt;- glm(DS1 ~ PSA + V, family=binomial(logit), data=mydata)</pre>	Построение модели множественной линейной регрессии методом включения всех предикторов:
<pre>mylogit1 DS1</pre>	имя модели; предсказываемое событие, должно иметь два возможных значения;
<pre>PSA, V mydata</pre>	независимые предикторы; имя массива данных для построения модели;
<pre>summary(mylogit1)</pre>	описание полученной модели;
<pre>mylogit1</pre>	имя модели, заданное при её построении

## Пример вывода результатов логистической регрессии в пакете R

```
Coefficients:
      Estimate Std. Error z value Pr(>|z|)
(Intercept) -1.273527   0.294750  -4.321  1.56e-05 ***
PSA          0.053281   0.010999   4.844  1.27e-06 ***
V           -0.006506   0.006673  -0.975  0.330
---
Signif. codes:  0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

### Обозначения

- Первый столбец (без заголовка) — свободный член (`intercept`) и предикторы в модели;
- `Estimate` — коэффициент регрессии;
- `Std. Error` — стандартная ошибка коэффициента регрессии;
- `z value` — стандартизованная статистика Вальда; с её помощью проверяют статистическую гипотезу отличия коэффициента регрессии от 0;
- `Pr(>|z|)` — уровень значимости предиктора, статистически значимые предикторы помечены звёздочками.

Для нахождения экспоненциальных коэффициентов регрессии (отношение шансов) необходимо выполнить команды:

```
exp(mylogit1$coefficients)
exp(confint(mylogit1))
```

*Примечание:* если модель регрессии названа не `mylogit1`, а как-то иначе, то имя модели и нужно указывать!

**Отразить в отчёте:** цель работы, полученное уравнение регрессии; статистическую значимость предикторов; экспоненциальные коэффициенты и их доверительные интервалы. Включает ли единицу доверительный интервал, в случае если коэффициент значимый и незначимый?

3. В Excel'e изобразите графически вероятность моделируемого события от одного из значимых предикторов, а другой зафиксируйте на двух значениях (по оси абсцисс — значения предиктора, по оси ординат — вероятность события). Найти диапазон изменений предикторов можно через описательные статистики.

Совет. Возьмите 15–20 значений независимого предиктора с равным шагом от минимального до максимального (по исходным дан-

ным). Построение графика в Excel удобно разделить на два этапа: вначале рассчитать шансы, потом вероятности предсказываемого события. Затем воспользоваться функцией «точечный график». Должна получиться S-образная кривая. Полученный график зарисовать в отчет.

## **КОНТРОЛЬНЫЕ ВОПРОСЫ**

1. В каких случаях можно рассчитывать коэффициент корреляции Пирсона, а в каких Спирмена или Кендалла?
2. Для чего предназначены диаграммы рассеяния?
3. Какая функция пакета R предназначена для построения линейной регрессии? Какие характеристики модели она возвращает?
4. Какие средства диагностики мультиколлинеарности предлагает пакет R?
5. Для чего предназначены диагностические графики остатков регрессии в пакете R?
6. Напишите уравнение логистической регрессии.
7. Как отличается интерпретация коэффициентов в линейной и логистической регрессии?

## РЕКОМЕНДУЕМЫЙ БИБЛИОГРАФИЧЕСКИЙ СПИСОК

1. Вараксин, А.Н. Статистические модели регрессионного типа в экологии и медицине [Текст] / А.Н. Вараксин. — Екатеринбург, 2006. — 256 с.
2. Дюк, В.А. Информационные технологии в медико-биологических исследованиях [Текст] / В.А. Дюк, В.Л. Эммануэль. — СПб.: Питер, 2003. — 528 с.
3. Плис, А.И. Практикум по прикладной статистике в среде SPSS [Текст]: учеб. пособие для студентов вузов. Ч.1. Классические процедуры статистики / А.И. Плис, Н.А. Сливина. — М.: Финансы и статистика, 2004. — 287 с.
4. Славин, М.Б. Методы системного анализа в медицинских исследованиях [Текст] / М.Б. Славин. — М.: Медицина, 1989. — 304 с.

Учебное издание

**КОРРЕЛЯЦИОННЫЙ И РЕГРЕССИОННЫЙ АНАЛИЗ  
МЕДИКО-БИОЛОГИЧЕСКИХ ДАННЫХ В СРЕДЕ  
СТАТИСТИЧЕСКОГО ПАКЕТА R**

*Методические указания к практическим занятиям*

Составитель ***Комарова Марина Валериевна***

Редактор Т.С. Петренко  
Доверстка Т.С. Петренко

Подписано в печать 20.05.2010. Формат 60×84 1/16.

Бумага офсетная. Печать офсетная.

Печ. л. 1,5

Тираж      экз. Заказ      .

Самарский государственный  
аэрокосмический университет.  
443086, Самара, Московское шоссе, 34.

---

Изд-во Самарского государственного  
аэрокосмического университета.  
443086, Самара, Московское шоссе, 34.