R, Quick start to data analysis

Alex Shlemov Anton Korobeynikov

4 октября 2014 г.

Содержание

1 Справка, workspaces, запуск скриптов, пакеты **2**
1.1 Справка . . . 2
1.2 Переменные, рабочие пространства (workspaces), история команд, выход 2
1.3 Запуск скриптов . . . 2
1.4 Пакеты . . . 3

2 Вектора, матрицы, массивы **3**
2.1 Вектора, основные операции . . . 3
2.2 Вектора, доступ к элементам (subscripting, индексная техника) . . . 7
2.2.1 Числовой вектор индексов . . . 8
2.2.2 Логический вектор-маска . . . 8
2.2.3 Строковый вектор имен . . . 9
2.3 Матрицы и массивы . . . 9
2.3.1 Создание и размерность матриц . . . 9
2.3.2 Операции с матрицами . . . 10
2.3.3 Функции для работы с матрицами . . . 11
2.3.4 Многомерные массивы . . . 12
2.4 Матрицы и массивы, доступ к элементам . . . 13
2.4.1 Обращение как к вектору . . . 13
2.4.2 Обращение к декартовому произведению измерений . . . 13
2.4.3 Обращение по многомерному индексу . . . 15

3 Списки **15**
3.1 Создание списка, склейка, повторение . . . 15
3.2 Обращение к элементам . . . 16
3.2.1 Взятие подсписка . . . 16
3.2.2 Взятие элемента . . . 17

4 Материалы с занятия 3 октября **18**
4.1 Toothgrowth . . . 18
4.2 Графики residuals-vs-fitted . . . 25
4.3 Линейная регрессия (Университеты) . . . 33
4.3.1 Advertising, окончательный результат . . . 46

5 Рисование **54**

1 Справка, workspaces, запуск скриптов, пакеты

1.1 Справка

```
help(package = package_name) # Справка по пакету
> help(package = lattice)

?function_name # Справка по функции
> ?ls

?"keyword" # Справка по ключевому слову
> ?"for"
> ?"+"
> ?"["
> ?"[[<-"
??pattern # Поиск по справке
> ??glm
apropos("pattern") # Возвращает найденные имена функций, подходящие под
    шаблон
> apropos("GLM")
```

1.2 Переменные, рабочие пространства (workspaces), история команд, выход

```
ls() # Возвращает вектор из имен переменных в текущем scope, если запущен в
    терминале, то возвращает имена переменных из рабочего workspace
ls(all.values = TRUE) # Возвращает ВСЕ имена переменных текущего scope
    (включая начинающиеся с .)

rm(varname) # Удаляет переменную. Имя без кавычек
rm(list = ls(all.values = TRUE)) # При вызове из терминала -- чистит
    workspace

save.image(file = "workspace_file_name.rda") # сохраняет workspace (проще
    говоря, все переменные) в файл
load.image(file = "workspace_file_name.rda") # Загружает workspace из файла

history(max.show = Inf) # Показывает историю команд
savehistory(file = "history_file_name.R") # Сохраняет историю команд в файл

q() # Выход из R
q("no") # Выход из R без сохранения workspace (предпочтительнее)
```

1.3 Запуск скриптов

```
source("script_file_name.R") # Выполняет скрипт из файла
```

Также есть утилита `Rscript`, которая позволяет выполнить R-файл прямо из командной строки:

```
> Rscript script.R
```

Можно включить ее в shabang и сделать скрипт исполняемым файлом (в Unix):

script.R

```
#!/usr/bin/Rscript

args <- commandArgs(TRUE) # Получить аргументы командной строки в виде
    вектора строк
print(args)
```

после чего:

```
> chmod +x script.R
> ./script.R just command line args 3 14 15
[1] "just"    "command" "line"    "args"    "3"       "14"      "15"
```

Если есть необходимость в детальном разборе аргументов командной строки, не нужно писать свой ~~велосипед~~ парсер, есть пакеты `getopt` и `optparse`.

1.4 Пакеты

```
library("package_name") # Подключает установленный пакет.
# Кавычки можно опустить:
> library(lattice)

install.package("package_name") # Устанавливает пакет с зеркала CRAN
> install.packages("latticeExtra")
```

При первом запуске в сессии `R` предложит выбрать зеркало CRAN, достаточно выбрать "Cloud" (первое в списке). Обратите внимание, что в Unix пакеты скачиваются в виде исходников и собираются у Вас на машине, поэтому должен быть установлен компилятор C/C++/fortran и необходимые библиотеки (причем девелоперские версии, в пакетном менеджере они обычно имеют суффикс "-dev", например "libfftw3-dev"). Под Windows пакеты скачиваются уже собранными.

При необходимости, можно установить сторонние пакеты из исходников. Для этого удобно пользоваться пакетом `devtools`:

```
install.packages("devtools")
library(devtools)
install_github("asl/rssa")
# Аналогично:
install_git(...); install_bitbucket(...); install_url(...); install_local
    (...)
```

Здесь пакет в любом случае будет собираться из исходников, под Windows нужно устанавливать и настраивать весь toolchain (msys + mingw + девелоперские либы). Под Unix могут понадобится некоторые стандартные утилиты типа `curl` (как правило, они уже установлены).

2 Вектора, матрицы, массивы

2.1 Вектора, основные операции

Начнем с того, что в `R` нет "скалярных" значений, любое скалярное значение (число, строка) это вектор длины 1. Вектора бывают следующих типов: `numeric, complex,`

logical, character, т.е. числовые, комплексные, булевские и строковые. Числовые вектора делятся на integer и double, но это деление исключительно внутреннее — при делении или выходе из диапазона целые числа автоматически приводятся к вещественному типу.

Создание и простейшая работа с векторами:

```
> v <- 1:10
> print(v)
[1]  1  2  3  4  5  6  7  8  9 10
> 10:1
[1] 10  9  8  7  6  5  4  3  2  1
> seq(1, 10, 2)
[1] 1 3 5 7 9
> seq(from = 10, by = 5, length.out = 6)
[1] 10 15 20 25 30 35

# Создание "пустых" векторов
> v <- numeric(10)
> v
[1] 0 0 0 0 0 0 0 0 0 0
> b <- logical(10)
> b
[1] FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE FALSE
> cplx <- complex(10)
> cplx
[1] 0+0i 0+0i 0+0i 0+0i 0+0i 0+0i 0+0i 0+0i 0+0i 0+0i
> ch <- character(10)
> ch
[1] "" "" "" "" "" "" "" "" "" ""

# Прочитать элемент
> v[2]
[1] 0
> ch[3]
[1] ""
> b[4]
[1] FALSE
> cplx[5]
[1] 0+0i

# Записать элемент
> v[6] <- 42
> ch[7] <- "Hello"
> b[8] <- TRUE
> i <- 9
> 4i + 3 -> cplx[i]

# Повторения
> rep(1:3, 5) # Последовательная склейка
```

```
[1] 1 2 3 1 2 3 1 2 3 1 2 3 1 2 3
> rep(1:3, each = 5) # И повтор каждого элемента
[1] 1 1 1 1 1 2 2 2 2 2 3 3 3 3 3

# Конкатенация (склейка)
> c(1:5, 5:1, 3:4)
[1] 1 2 3 4 5 5 4 3 2 1 3 4
```

Немного служебных операций. Вывод:

```
> print(ch)
[1] ""      ""      ""      ""      ""      ""      "Hello" ""      ""
[10] ""
```

Если Вы работаете в командной сессии, то выводится результат каждой выполненной команды. Но если Вы проводите какие-то действия в цикле, в функции, в вызываемом по `source()` или `Rscript` скрипте, то желаемый вывод необходимо делать явно.

Кстати говоря, если Вы работаете в командной строке, то переменная `.Last.value` всегда содержит результат последней команды:

```
> 2 + 2
[1] 4
> print(.Last.value)
[1] 4
```

Summary:

```
> summary(1:10)
   Min. 1st Qu.  Median    Mean 3rd Qu.    Max.
   1.00    3.25    5.50    5.50    7.75   10.00
```

Вообще `summary()` (как, кстати, и `print()`) — это полиморфные функции, для каждого типа объекта они определены по-своему. Для числовых векторов `summary()` выводит квантили и среднее. Незамысловато, но бывает полезно.

Длина вектора:

```
> length(v)
[1] 10
> length(v) <- 5
> v
[1] 0 0 0 0 0
> length(v) <- 10
> v
[1]  0  0  0  0  0 NA NA NA NA NA
```

Функция `length()` работает и на присваивание. При попытке увеличить длину вектора новые элементы получают значение `NA`, т.е. пропущенное значение.

Тип вектора:

```
> mode(v) # Логический тип (mode)
[1] "numeric"
> storage.mode(v) # Хранимый тип. Нужен редко, в основном, если хочется
    передать указатель на объект "наружу"
[1] "double"
```

Обе функции работают на присваивание, изменяя тип объекта.

Также можно совершить приведение типа с помощью функций `as.whatever()`:

```
> as.character(10)
[1] "10"
> as.logical(10)
[1] TRUE
> as.numeric("33.5")
[1] 33.5
> as.integer("33.5")
[1] 33
> as.integer(33.5)
[1] 33
```

Все стандартные операции с векторами векторизованы, т.е. выполняются поэлементно:

```
> 1:10 + 10:1
[1] 11 11 11 11 11 11 11 11 11 11
> sin(1:10)
[1]  0.8414710  0.9092974  0.1411200 -0.7568025 -0.9589243 -0.2794155
[7]  0.6569866  0.9893582  0.4121185 -0.5440211
```

При этом если в бинарной операции встречаются вектора неодинаковой длины, то используются так называемое переписывание (recycling), вектор меньшей длины автоматически повторяется нужное число раз:

```
> 1:10 + 1:5
[1]  2  4  6  8 10  7  9 11 13 15
```

При этом, если длина меньшего вектора не является делителем длины большей, будет выведено предупреждение (warning):

```
> 1:10 + 1:3
[1]  2  4  6  5  7  9  8 10 12 11
Warning message:
In 1:10 + 1:3 :
 longer object length is not a multiple of shorter object length
```

Обычно меньший вектор имеет длину 1 и такой проблемы не возникает:

```
> (1:10)^2
[1]   1   4   9  16  25  36  49  64  81 100
```

Кстати, степень имеет более высокий приоритет, чем “ :”:

```
> 1:3^2
[1] 1 2 3 4 5 6 7 8 9
```

Полезные векторизованные функции:

```
a + b, a - b, a * b, a / b # 4 действия арифметики
a ^ b # степень
a %/% b, a %% b # целочисленное деление и взятие остатка

exp(x), log(x) # экспонента и логарифм
```

```
abs(x) # Модуль

Re(z), Im(z), Conj(z), Mod(z), Arg(z) # Вещественная и мнимая часть,
    комплексное сопряжение, модуль и аргумент

cos(x), sin(x), tan(x), acos(x), asin(x), atan(x), atan2(y, x) #
    Тригонометрия

x == y, x != y, x > y, x >= y, etc # поэлементные сравнения
> 1:10 > 5
[1] FALSE FALSE FALSE FALSE FALSE  TRUE  TRUE  TRUE  TRUE  TRUE

x & y, x | y, xor(x, y) # булевские поэлементные операции
x && y, x || y # булевские операции для векторов длины 1, вычисляемые по
    короткой схеме
```

Агрегирующие функции. Наряду с поэлементной векторизацией (любители функционального программирования назвали бы ее “map”) есть функции, сопоставляющие вектору единичное значение (любители ФП назвали бы это “reduce”). Вот примеры таких функций:

```
sum(x), prod(x) # Сумма и произведение всех элементов
max(x), min(x), which.max(), which.min() # Максимум-минимум и индекс
    максимального и минимального элемента

mean(), sd(), cov(), cor(), median(), mad(), quantile() # Статистические
    функции

all(x), any(x) # Логические функции, возвращают TRUE, если все (или хотя бы
    один) из элементов вектора истина
```

2.2 Вектора, доступ к элементам (subscripting, индексная техника)

Доступ к элементам вектора осуществляется с помощью оператора “[” (“subscript”). Доступ работает как на чтение, так и на запись:

```
x[?]
x[?] <- y
```

Чтение возвращает подвектор (возможно, что пустой). При записи подвектор перезаписывается значениями из вектора, стоящего в правой части (`y`). Если длины перезаписываемого подвектора и правой части не совпадают, применяется переписывание (если количество заменяемых значений не делится на количество новых, то выводится предупреждение).

Что может стоять внутри “[ ]”?

2.2.1 Числовой вектор индексов

Все нецелые значения приводятся к целым (отбрасывается дробная часть). Нули отбрасываются. Для положительных индексов возвращаются соответсвующие элементы (нумерация от единицы!!!):

```
> v <- c("a", "b", "c", "d", "e", "f", "g", "h")
> v[c(1, 3, 5.9)]
[1] "a" "c" "e"
> v[c(1, 3, 5.9)] <- "X"
> v
[1] "X" "b" "X" "d" "X" "f" "g" "h"
```

Для отрицательных возвращаются все элементы, кроме названных:

```
> v[-c(2, 4, 7.7)]
[1] "X" "X" "X" "f" "h"
> v[-c(2, 4, 7.7)] <- Y
Error: object 'Y' not found
> v[-c(2, 4, 7.7)] <- "Y"
> v
[1] "Y" "b" "Y" "d" "Y" "Y" "g" "Y"
```

Смешивать отицательные и положительные индексы нельзя. На чтение положительные индексы можно дублировать:

```
> v
[1] "Y" "b" "Y" "d" "Y" "Y" "g" "Y"
> v[c(1, 1, 1, 2)]
[1] "Y" "Y" "Y" "b"
```

На запись тоже можно, но в таком случае элемент с повторенным индексом будет перезаписан несколько раз и в итоге в нем окажется последний записанный элемент:[1]

```
> v[c(1, 1, 1)] <- c("X", "Y", "Z")
> v
[1] "Z" "b" "c"
```

2.2.2 Логический вектор-маска

Выбираются элементы, соответствующие “`TRUE`”. Если вектор недостаточной длины, используется переписывание (если длина маски не делит длину вектора, то выведется соответствующее предупреждение). Если вектор-маска больше длины вектора, то вектор удлиняется до необходимой длины и дополняется пропусками (`NA`).

```
> v <- 1:10
> v[c(TRUE, FALSE)] # Выбрать четные элементы
[1] 1 3 5 7 9
> v[c(TRUE, FALSE)] <- 42 # Заменить четные элементы
> v
[1] 42  2 42  4 42  6 42  8 42 10
```

В основном, в качестве логической маски используются выражения-“запросы”:

[1] Лично я считаю, что использовать повторные индексы на запись — очень скверная идея.

```
> v[v > 6] <- 0 # Заменить элементы > 6
> v
[1] 0 2 0 4 0 6 0 0 0 0
```

Тут нет никакой магии — `(v > 6)` возвращает логический вектор.

2.2.3 Строковый вектор имен

Для того, чтобы обращаться к элементам вектора по именам, необходимо эти имена назначить. У каждого вектора есть возможность установить атрибут `names` — строковый вектор такой же длины, как и сам вектор:

```
> v <- 1:3
> names(v) <- c("a", "b", "c")
> v
a b c
1 2 3
> names(v)
[1] "a" "b" "c"
```

Вектор стал именованным. Теперь если передать в качестве индекса строковый вектор, будут выбраны соответствующие элементы:

```
> v[c("a", "b")]
a b
1 2
> v[c("a", "b")] <- 42
> v
 a  b  c
42 42  3
```

2.3 Матрицы и массивы

2.3.1 Создание и размерность матриц

Матрица создается с помощью одноименной команды:

```
> m <- matrix(1:9, 3, 3)
> m
     [,1] [,2] [,3]
[1,]    1    4    7
[2,]    2    5    8
[3,]    3    6    9
```

Матрицы в `R` представляют собой вектор (с разверткой FORTRAN-style, т.е. по столбцам) со специальным атрибутом размерности:

```
> dim(m)
[1] 3 3
> length(m)
[1] 9
> dim(m) <- c(1, 9)
> m
```

```
      [,1] [,2] [,3] [,4] [,5] [,6] [,7] [,8] [,9]
[1,]    1    2    3    4    5    6    7    8    9
```

Как видите, атрибут доступен на запись, единственное, необходимо, чтобы `prod(dim(x)) = length(x)`.

Также есть функции `nrow()` и `ncol()`, возвращают число строк и столбцов соответственно.

2.3.2 Операции с матрицами

Так как матрицы являются векторами, для них можно делать те же операции, что и для векторов; при этом размерность будет сохраняться:

```
> m <- matrix(1:9, 3, 3)
> sin(m)
          [,1]       [,2]      [,3]
[1,] 0.8414710 -0.7568025 0.6569866
[2,] 0.9092974 -0.9589243 0.9893582
[3,] 0.1411200 -0.2794155 0.4121185
> m + m
     [,1] [,2] [,3]
[1,]    2    8   14
[2,]    4   10   16
[3,]    6   12   18
> m ^ 2
     [,1] [,2] [,3]
[1,]    1   16   49
[2,]    4   25   64
[3,]    9   36   81
> m * 2
     [,1] [,2] [,3]
[1,]    2    8   14
[2,]    4   10   16
[3,]    6   12   18
> m * m
     [,1] [,2] [,3]
[1,]    1   16   49
[2,]    4   25   64
[3,]    9   36   81
> m > 10
      [,1]  [,2]  [,3]
[1,] FALSE FALSE FALSE
[2,] FALSE FALSE FALSE
[3,] FALSE FALSE FALSE
> m > 5
      [,1]  [,2] [,3]
[1,] FALSE FALSE TRUE
[2,] FALSE FALSE TRUE
[3,] FALSE  TRUE TRUE
```

Обратите внимание, что произведение матриц — поэлеметное. Если мы хотим получить обычное операторное произведение, следует использовать `%*%`:

```
> m %*% m
     [,1] [,2] [,3]
[1,]   30   66  102
[2,]   36   81  126
[3,]   42   96  150
```

Вектор без атрибута размерности считается вектор-столбцом, но при умножении вектора на матрицу слева вектор автоматически транспонируется:

```
> m
     [,1] [,2] [,3]
[1,]    1    4    7
[2,]    2    5    8
[3,]    3    6    9
> m %*% 1:3
     [,1]
[1,]   30
[2,]   36
[3,]   42
> 1:3 %*% m
     [,1] [,2] [,3]
[1,]   14   32   50
```

Обратите внимание, что умножение "$*$" это поэлеметное умножение каждого столбца на вектор:

```
> m * 1:3
     [,1] [,2] [,3]
[1,]    1    4    7
[2,]    4   10   16
[3,]    9   18   27
```

2.3.3 Функции для работы с матрицами

:

```
solve(m) # обратная матрица
solve(m, y) # m^{-1}y, но вычисляется устойчивее
t(m) # транспонирование

qr(m), eigen(m), svd(m), chol(m) # классические матричные разложения (QR,
    EVD, SVD и разложение Холецкого)

crossprod(x, y) # x^T y, но вычисляется немного быстрее
tcrossprod(x, y) # xy^T, аналогично
crossprod(x), tcrossprod(x) # умножение саму на себя: x^T x и xx^T

diag(m) # для матрицы, возвращает вектор главной диагонали, при этом
    доступна на запись
```

```
> m <- matrix(1:9, 3, 3)
> diag(m)
[1] 1 5 9
> diag(m) <- -diag(m)
> m
     [,1] [,2] [,3]
[1,]   -1    4    7
[2,]    2   -5    8
[3,]    3    6   -9
diag(n) # для числа -- возвращает единичную матрицу порядка n
> diag(3)
     [,1] [,2] [,3]
[1,]    1    0    0
[2,]    0    1    0
[3,]    0    0    1
```

Слейка матриц:

```
cbind(a, b, c, ...) # Склейка матриц по столбцам: [a : b : c : ...]
rbind(a, b, c, ...) # Склейка матриц по строкам (вертикально)
```

Если вектор (не матрицу) передать на вход `cbind()`, то он будет рассматриваться как столбец, а если `rbind()` — то как строка. При этом для векторов и матриц работают правила переписывания.

Сумма и среднее по строкам и столбцам:

```
> m <- matrix(1:9, 3, 3)
> rowMeans(m)
[1] 4 5 6
> colMeans(m)
[1] 2 5 8
> rowSums(m)
[1] 12 15 18
> colSums(m)
[1]  6 15 24
```

2.3.4 Многомерные массивы

Также, кроме матриц присутствуют и многомерные массивы (тензоры) `array()`:

```
> a <- array(1:8, dim = c(2, 2, 2))
> a
, , 1

     [,1] [,2]
[1,]    1    3
[2,]    2    4

, , 2

     [,1] [,2]
```

```
[1,]    5    7
[2,]    6    8
```

2.4 Матрицы и массивы, доступ к элементам

Обсудим обращение к элементам матриц и многомерных массивов. Аналогично векторам, обращение возможно как на чтение, так и на запись

2.4.1 Обращение как к вектору

И матрица, и массив являются вектором, следовательно, для них работают те же методы индексирования, что и для векторов, при этом. напоминаю, матрица укладывается в вектор по столбцам. На практике, пожалуй, из этого может быть полезна только техника “логических запросов” типа:

```
m[m > 10]
m[m < 0] <- 0
```

2.4.2 Обращение к декартовому произведению измерений

Для обращения к матрице можно использовать двухиндексную технику (а для обращения к массивам — r-индексную, где r — количество измерений):

```
m[i, j]
a[i, j, k]
```

где `i, j, k` могут быть числовыми, логическими или строковыми векторами. Результатом будет подмассив той же структуры (подвыборка произойдет независимо по всем измерениям).

```
> m <- matrix(1:9, 3, 3)
> m
     [,1] [,2] [,3]
[1,]    1    4    7
[2,]    2    5    8
[3,]    3    6    9
> m[c(TRUE, FALSE, TRUE), -1] # Выбрать 1 и 3 строки и отбросить 1 столбец
     [,1] [,2]
[1,]    4    7
[2,]    6    9
```

Чтобы иметь возможность обращаться к строкам и столбцам матрицы по именам, нужно задать атрибуты `colnames` и `rownames` (а в случае массива — атрибут `dimnames`):

```
> m <- matrix(1:9, 3, 3)
> rownames(m) <- c("a", "b", "c")
> colnames(m) <- c("x", "y", "z")
> m[c("a", "c"), c("y", "y", "x")]
  y y x
a 4 4 1
c 6 6 3
```

```
> a <- array(1:8, dim = c(2, 2, 2))
> dimnames(a) <- list(c("a", "b"), c("i", "j"), c("x", "y"))
> a
, , x

  i j
a 1 3
b 2 4

, , y

  i j
a 5 7
b 6 8
> a["a", "j", "y"]
[1] 7
```

Нужно отметить две тонкости. Во-первых, один или несколько индексов можно опускать, это будет означать выбор всего диапазона. Во-вторых, если в результате выбора полученный массив будет иметь меньшую размерность, чем исходный (например, выбираем строку из матрицы), то вырожденные измерения автоматически "схлопнутся" (drop):

```
m <- matrix(1:9, 3, 3)
m

##      [,1] [,2] [,3]
## [1,]    1    4    7
## [2,]    2    5    8
## [3,]    3    6    9

m[1, ]

## [1] 1 4 7

m[, 1]

## [1] 1 2 3
```

В большинстве случаев это удобно: когда мы извлекаем строку или столбец, более приятно получать вектор, а не длинную матрицу. Но иногда требуется, чтобы подмассив имел строго такую же размерность, как и исходный массив. Чтобы избежать схлопывания и получить массив той же размерности нужно явно указать:

```
m <- matrix(1:9, 3, 3)
m[1, , drop = FALSE]

##      [,1] [,2] [,3]
## [1,]    1    4    7
```

```
m[, 1, drop = FALSE]

##      [,1]
## [1,]    1
## [2,]    2
## [3,]    3
```

2.4.3 Обращение по многомерному индексу

Можно передать в `[ ]` матрицу из r столбцов и n строк, где r — число измерений (2 для матрицы). В результате каждая строка будет рассматриваться как набор координат выбираемого элемента и результатом будет вектор длины n:

```
> m <- matrix(1:9, 3, 3)
> m[cbind(1:ncol(m), ncol(m):1)] # Антидиагональ
[1] 7 5 3
```

3 Списки

Список — это вектор, который может хранить элементы различных типов. В отличие от Python, нет возможности создать рекурсивный список (так как копирование всегда происходит по значению).

3.1 Создание списка, склейка, повторение

```
l <- list(a = 1, b = "string", f = q) # Может хранить объекты разных типов
l

## $a
## [1] 1
##
## $b
## [1] "string"
##
## $f
## function (save = "default", status = 0, runLast = TRUE)
## .Internal(quit(save, status, runLast))
## <bytecode: 0x26501c0>
## <environment: namespace:base>

l <- list(a = 1, 2) # Не обязательно все элементы должны иметь имена
l

## $a
## [1] 1
##
## [[2]]
## [1] 2
```

```r
l <- as.list(1:3)
l

l1 <- list(1, "A")
l2 <- list("b", 10)
c(l1, l2) # Списки можно склеивать

rep(l1, 5) # И повторять
```

3.2 Обращение к элементам

3.2.1 Взятие подсписка

Для списков оператор `[` работает также, как и для векторов, только возвращается не подвектор, а подсписок:

```r
l <- list(a = 1, b = "string", d = TRUE)
l[1:2]
```

```
## $a
## [1] 1
##
## $b
## [1] "string"
```

```r
l[-2]
```

```
## $a
## [1] 1
##
## $d
## [1] TRUE
```

```r
l[c("a", "b")]
```

```
## $a
## [1] 1
##
## $b
## [1] "string"
```

```r
l[1:2] <- list(5, "char")
l
```

```
## $a
## [1] 5
##
## $b
## [1] "char"
##
## $d
## [1] TRUE
```

3.2.2 Взятие элемента

Оператор `[[` позволяет обратиться к элементу:

```
l[[1]]

## [1] 5

l[["d"]] <- list(42)
l

## $a
## [1] 5
##
## $b
## [1] "char"
##
## $d
## $d[[1]]
## [1] 42
```

Также к элементам списка можно обращаться через оператор `$`:

```
ll <- list(a = 1, b = 2, "ccc")
ll$a

## [1] 1

ll$b <- 42
ll$c # При чтении достаточно уникального префикса

## NULL

ll

## $a
## [1] 1
##
## $b
## [1] 42
##
## [[3]]
## [1] "ccc"

ll$c <- 42 # А при записи будет создан элемент с переданным именем
ll

## $a
## [1] 1
##
```

```
## $b
## [1] 42
##
## [[3]]
## [1] "ccc"
##
## $c
## [1] 42
```

Присваивание элементу значения удаляет элемент:

```
l

## $a
## [1] 5
##
## $b
## [1] "char"
##
## $d
## $d[[1]]
## [1] 42

l[[1]] <- NULL
l$d <- NULL
l

## $b
## [1] "char"
```

Если Вам по каким-то причинам надо положить в список, то это делается так:

```
l[1] <- list(NULL)
```

4 Материалы с занятия 3 октября

4.1 Toothgrowth

```
read_chunk("qualitative.R")
```

```
library(lattice)
library(latticeExtra)

## Loading required package: RColorBrewer
```

```r
library(MASS)

tooth <- read.table("toothgrowth.txt")


tooth$supp <- factor(tooth$supp, labels = c("Orange juice", "Ascorbic acid"))
tooth$supp <- factor(tooth$supp, levels = c("Orange juice", "Ascorbic acid"))



bwplot(~len | supp * dose, data = tooth)
```

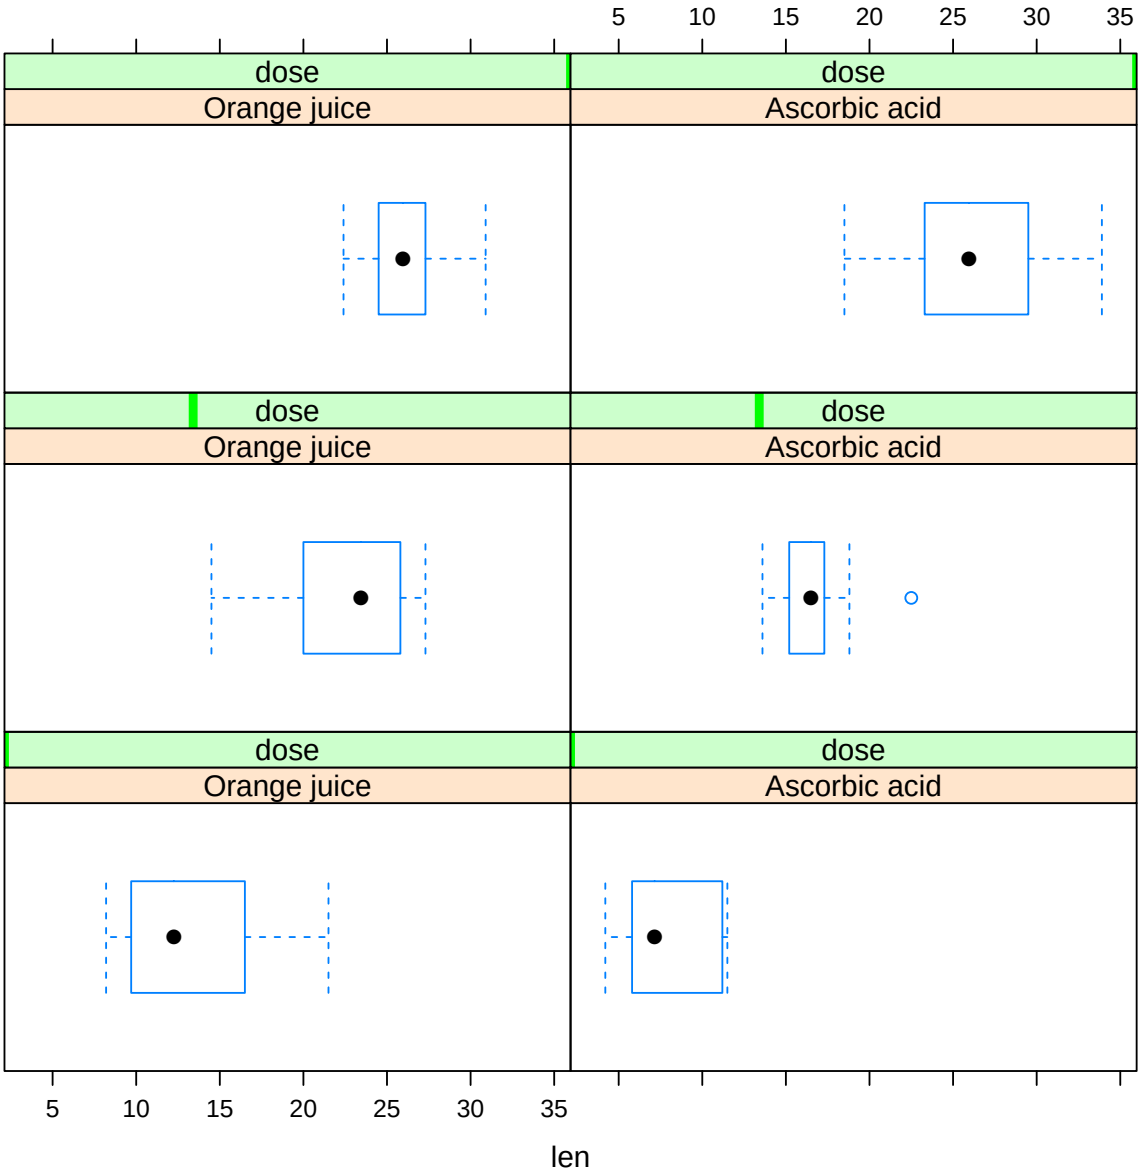


```r
bwplot(~len | dose * supp, data = tooth)
```

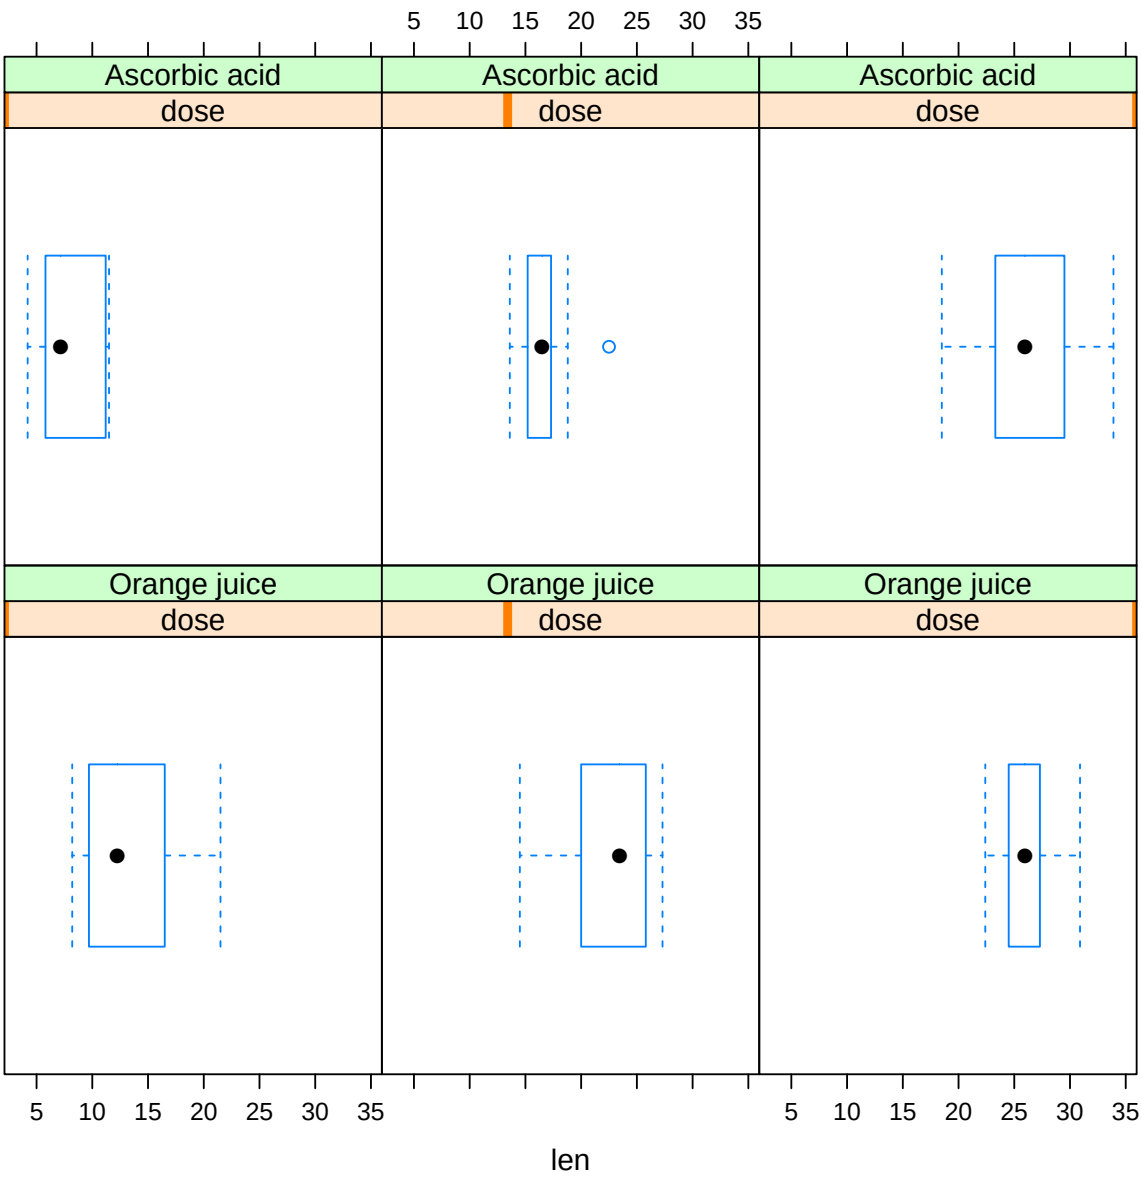


```
contrasts(tooth$supp)

##                Ascorbic acid
## Orange juice               0
## Ascorbic acid              1

contrasts(tooth$supp) <- contr.sum
contrasts(tooth$supp)

##                [,1]
## Orange juice      1
## Ascorbic acid    -1

l <- lm(len ~ supp + dose, data = tooth)
summary(l)
```

```
##
## Call:
## lm(formula = len ~ supp + dose, data = tooth)
##
## Residuals:
##    Min     1Q Median     3Q    Max
## -6.600 -3.700  0.373  2.116  8.800
##
## Coefficients:
##             Estimate Std. Error t value Pr(>|t|)
## (Intercept)    7.422      1.160    6.40  3.2e-08 ***
## supp1          1.850      0.547    3.38   0.0013 **
## dose           9.764      0.877   11.14  6.3e-16 ***
## ---
## Signif. codes:
## 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 4.24 on 57 degrees of freedom
## Multiple R-squared:  0.704,Adjusted R-squared:  0.693
## F-statistic: 67.7 on 2 and 57 DF,  p-value: 8.72e-16
```

```r
l <- lm(len ~ supp * dose, data = tooth)
summary(l)
```

```
##
## Call:
## lm(formula = len ~ supp * dose, data = tooth)
##
## Residuals:
##    Min     1Q Median     3Q    Max
##  -8.23  -2.85   0.05   2.29   7.94
##
## Coefficients:
##             Estimate Std. Error t value Pr(>|t|)
## (Intercept)    7.422      1.118    6.64  1.4e-08 ***
## supp1          4.127      1.118    3.69  0.00051 ***
## dose           9.764      0.845   11.55  < 2e-16 ***
## supp1:dose    -1.952      0.845   -2.31  0.02463 *
## ---
## Signif. codes:
## 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 4.08 on 56 degrees of freedom
## Multiple R-squared:  0.73,Adjusted R-squared:  0.715
## F-statistic: 50.4 on 3 and 56 DF,  p-value: 6.52e-16
```

```r
tooth$dose <- factor(tooth$dose, ordered = TRUE)
contrasts(tooth$dose)
```

```
##               .L      .Q
## [1,] -7.071e-01  0.4082
## [2,] -7.850e-17 -0.8165
## [3,]  7.071e-01  0.4082

contrasts(tooth$dose) <- contr.helmert
contrasts(tooth$dose)

##     [,1] [,2]
## 0.5   -1   -1
## 1      1   -1
## 2      0    2

l <- lm(len ~ supp * dose, data = tooth)
summary(l)

##
## Call:
## lm(formula = len ~ supp * dose, data = tooth)
##
## Residuals:
##    Min     1Q Median     3Q    Max
##  -8.20  -2.72  -0.27   2.65   8.27
##
## Coefficients:
##             Estimate Std. Error t value Pr(>|t|)
## (Intercept)   18.813      0.469   40.13  < 2e-16 ***
## supp1          1.850      0.469    3.95  0.00023 ***
## dose1          4.565      0.574    7.95  1.2e-10 ***
## dose2          3.643      0.332   10.99  2.2e-15 ***
## supp1:dose1    0.170      0.574    0.30  0.76831
## supp1:dose2   -0.945      0.332   -2.85  0.00617 **
## ---
## Signif. codes:
## 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 3.63 on 54 degrees of freedom
## Multiple R-squared:  0.794,Adjusted R-squared:  0.775
## F-statistic: 41.6 on 5 and 54 DF,  p-value: <2e-16

stepAIC(l)

## Start:  AIC=160.4
## len ~ supp * dose
##
##             Df Sum of Sq RSS AIC
## <none>                   712 160
## - supp:dose  2       108 820 165
##
```

```
## Call:
## lm(formula = len ~ supp * dose, data = tooth)
##
## Coefficients:
## (Intercept)        supp1        dose1        dose2
##      18.813        1.850        4.565        3.643
## supp1:dose1  supp1:dose2
##       0.170       -0.945

l.lin <- lm(len ~ supp + dose, data = tooth)

# the smaller AIC/BIC, the better the fit
AIC(l, l.lin)

##       df   AIC
## l      7 332.7
## l.lin  5 337.2

BIC(l, l.lin)

##       df   BIC
## l      7 347.4
## l.lin  5 347.7

anova(l, l.lin)

## Analysis of Variance Table
##
## Model 1: len ~ supp * dose
## Model 2: len ~ supp + dose
##   Res.Df RSS Df Sum of Sq    F Pr(>F)
## 1     54 712
## 2     56 820 -2      -108 4.11  0.022 *
## ---
## Signif. codes:
## 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

tooth.agg <- aggregate(subset(tooth, select = len),
                       list(supp = tooth$supp, dose = tooth$dose),
                       mean)

dp <- dotplot(factor(dose) ~ len, groups = supp, data = tooth.agg,
              auto.key = list(title = "Delivery", corner = c(0, 1)),
              type = "b",
              xlab = "mean(tooth length)",
              ylab = "Vitamin C dose",
              par.settings = simpleTheme(pch = 19))
```

```r
vp <- bwplot(factor(dose) ~ len, groups = supp, data = tooth,
             panel = function(...) {
               panel.superpose(...,
                               col = trellis.par.get("superpose.polygon")$col,
                               panel.groups = panel.violin)
             },
             auto.key = list(title = "Delivery method", corner = c(0, 1),
                             points = FALSE, lines = FALSE, rectangles = TRUE),
             xlab = "Tooth length",
             ylab = "Vitamin C dose",
             par.settings = simpleTheme(alpha = 0.6, pch = 19))

vp + dp
```

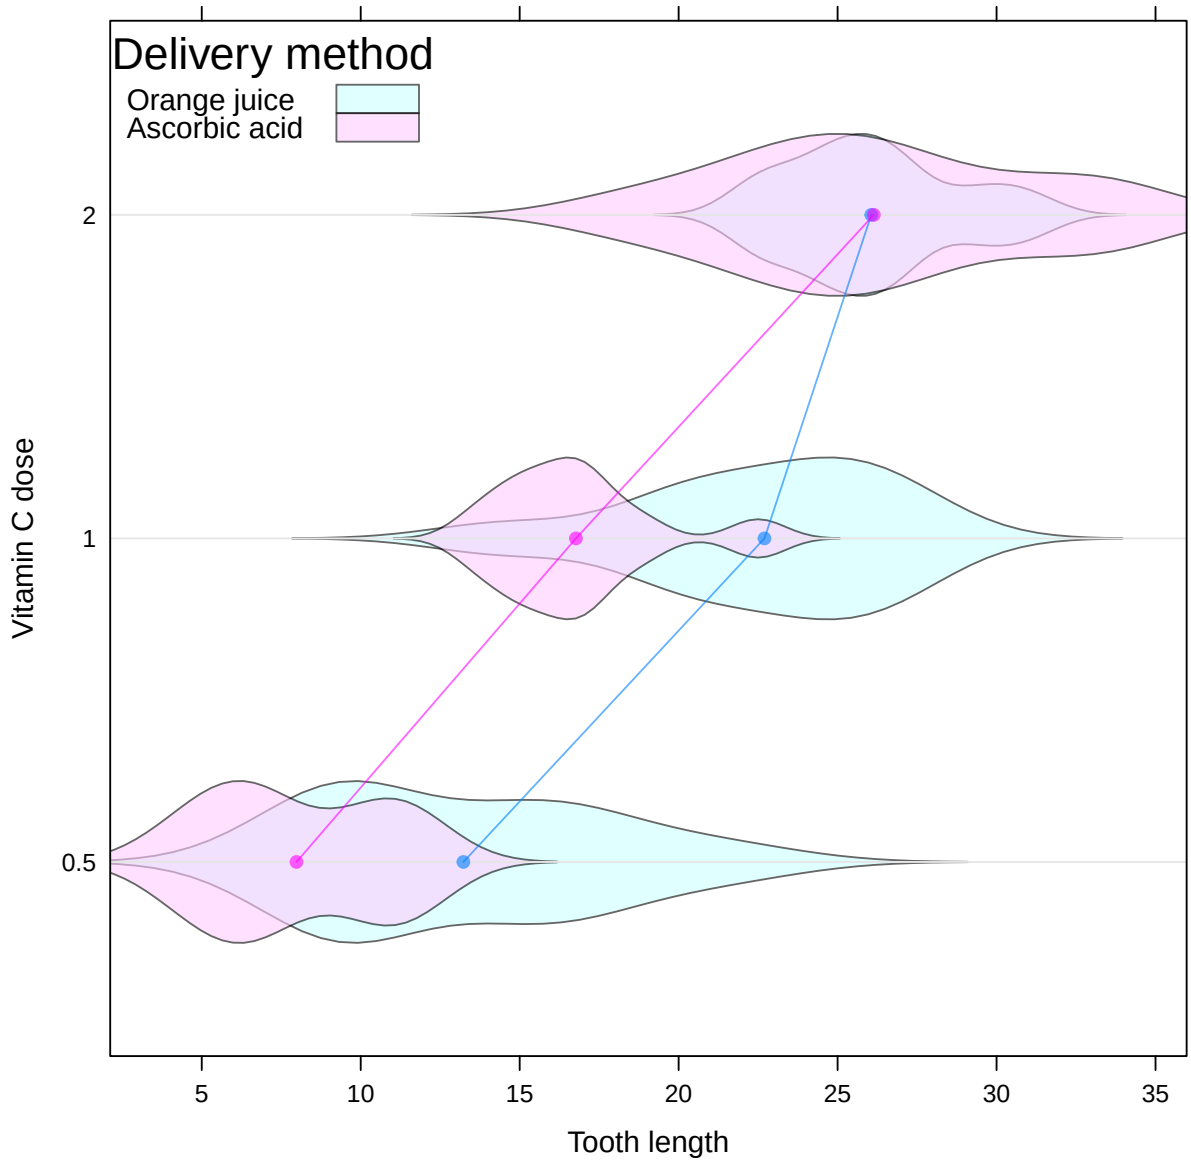

4.2 Графики residuals-vs-fitted

```
read_chunk("resfitted.R")
```

```
library(lattice)
library(latticeExtra)
library(MASS)

panel <- function(...) {
  panel.xyplot(...)
  panel.lmline(...)
}


N <- 1000
x <- rnorm(N)
beta0 <- 1
beta1 <- 2
beta1_2 <- 0.5

y <- beta0 + beta1 * x + beta1_2 * x ^ 2 + rnorm(N, sd = 0.1)

df <- data.frame(y = y, x = x)

l <- lm(y ~ x, data = df)
l2 <- lm(y ~ poly(x, degree = 2), data = df)

p1 <- xyplot(residuals(l) ~ fitted(l), panel = panel)
p2 <- xyplot(residuals(l2) ~ fitted(l2), panel = panel)


plot(c(linear = p1, quadratic = p2))
```

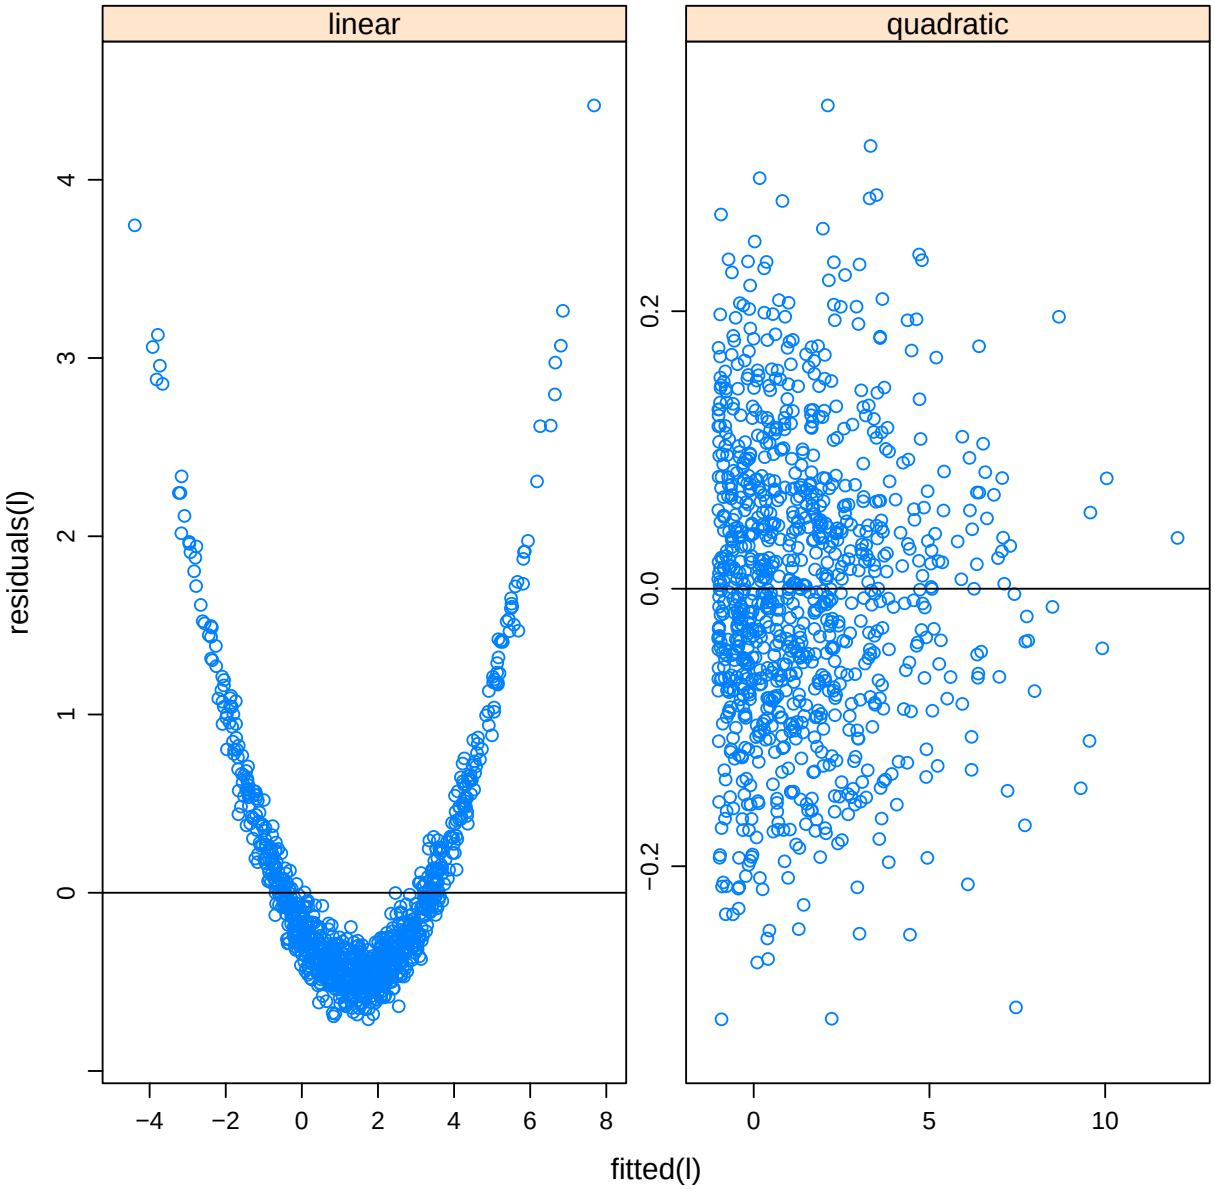


```
y <- exp(beta0 + beta1 * x + rnorm(N, sd = 0.5))

df <- data.frame(y = y, x = x)

l <- lm(y ~ x, data = df)
l2 <- lm(log(y) ~ x, data = df)
p1 <- xyplot(residuals(l) ~ fitted(l), panel = panel)
p2 <- xyplot(residuals(l2) ~ fitted(l2), panel = panel)
plot(c(original = p1, logarithm = p2))
```

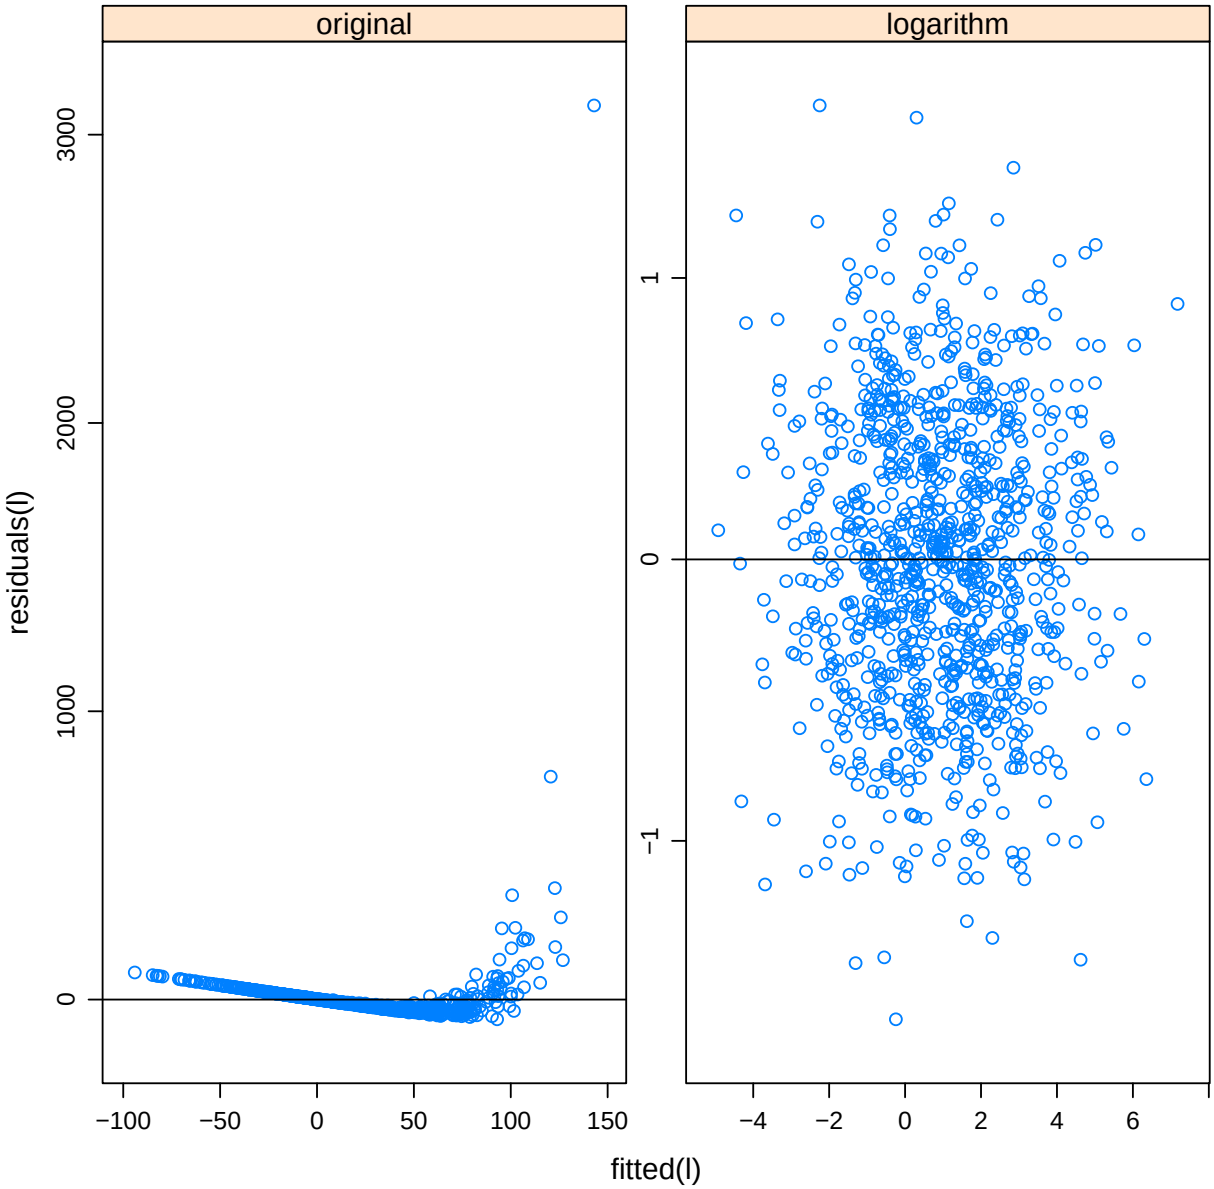


```
Auto <- read.table("Auto.data", header = TRUE, na.strings="?")
Auto <- na.omit(Auto)
xyplot(mpg ~ horsepower, data = Auto)
```

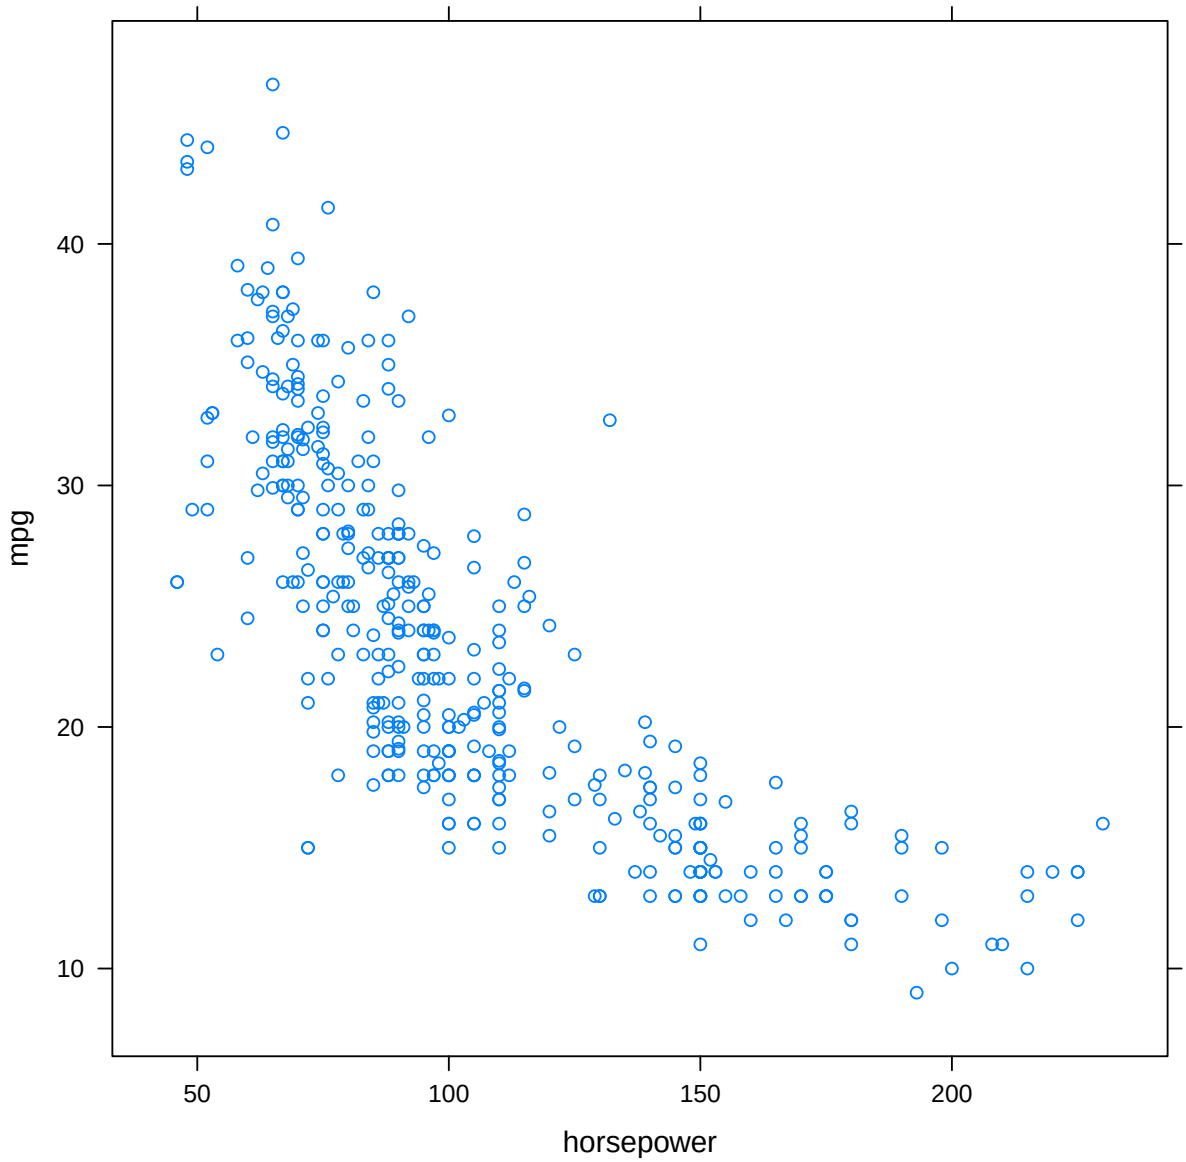


```
xyplot(mpg ~ log(horsepower), data = Auto)
```

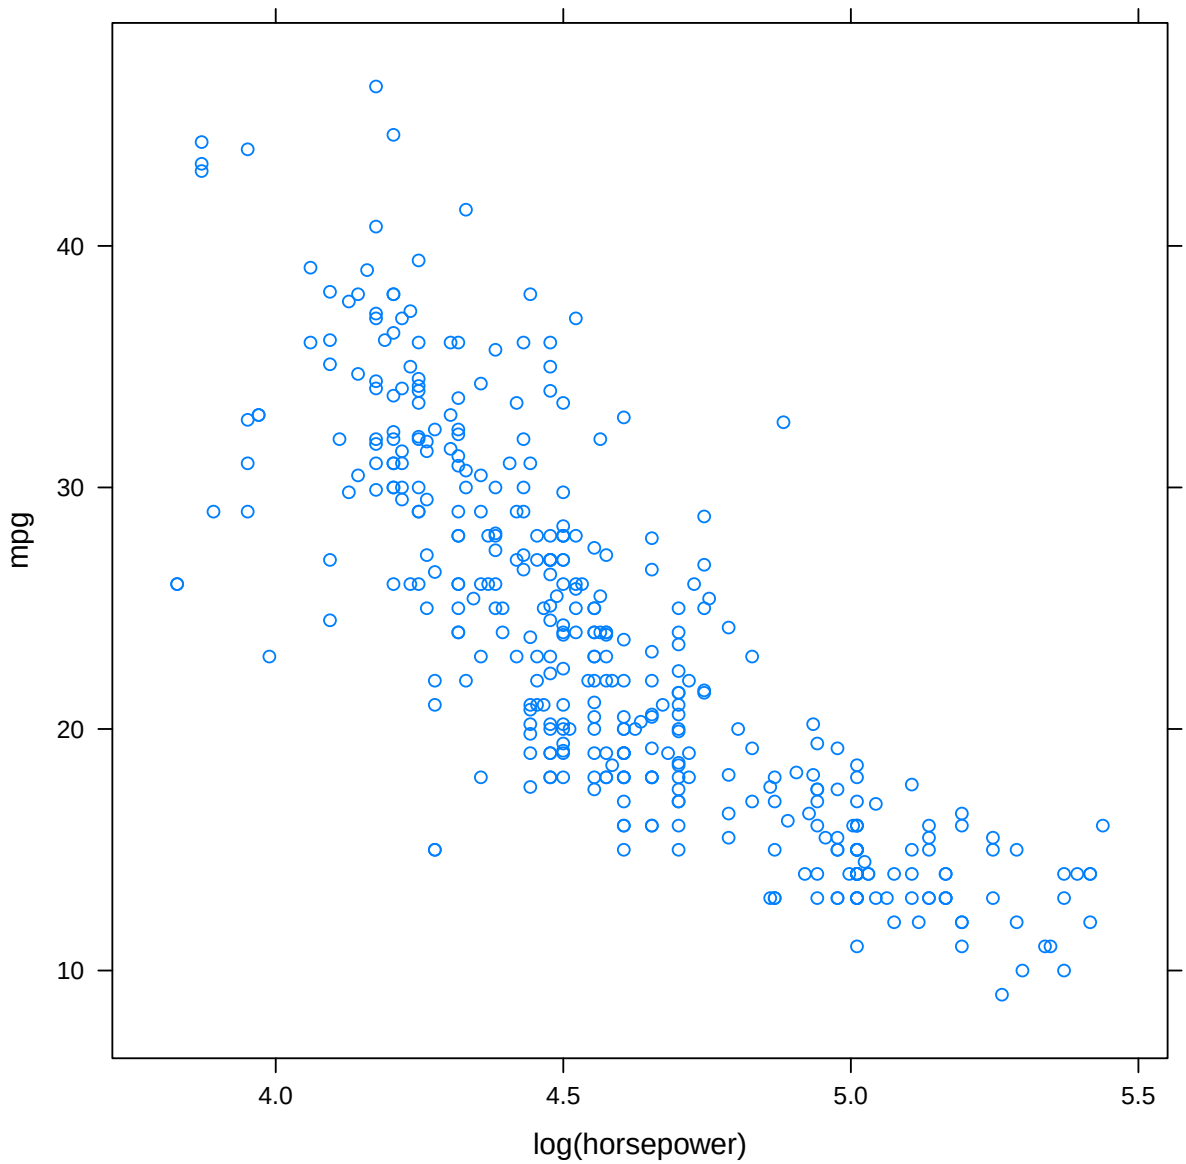


```
l1 <- lm(mpg ~ horsepower, data = Auto)
l2 <- lm(mpg ~ poly(horsepower, degree = 2), data = Auto)
llog <- lm(mpg ~ log(horsepower), data = Auto)
l5 <- lm(mpg ~ poly(horsepower, degree = 5), data = Auto)
l6 <- lm(mpg ~ poly(horsepower, degree = 6), data = Auto)
summary(l1)

##
## Call:
## lm(formula = mpg ~ horsepower, data = Auto)
##
## Residuals:
##     Min      1Q  Median      3Q     Max
## -13.571  -3.259  -0.344   2.763  16.924
##
```

```
## Coefficients:
##             Estimate Std. Error t value Pr(>|t|)
## (Intercept) 39.93586    0.71750    55.7   <2e-16 ***
## horsepower  -0.15784    0.00645   -24.5   <2e-16 ***
## ---
## Signif. codes:
## 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 4.91 on 390 degrees of freedom
## Multiple R-squared:  0.606,Adjusted R-squared:  0.605
## F-statistic:  600 on 1 and 390 DF,  p-value: <2e-16
```

```r
summary(llog)
```

```
##
## Call:
## lm(formula = mpg ~ log(horsepower), data = Auto)
##
## Residuals:
##     Min      1Q  Median      3Q     Max
## -14.230  -2.782  -0.232   2.666  15.470
##
## Coefficients:
##                 Estimate Std. Error t value Pr(>|t|)
## (Intercept)      108.700      3.050    35.6   <2e-16 ***
## log(horsepower)  -18.582      0.663   -28.0   <2e-16 ***
## ---
## Signif. codes:
## 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 4.5 on 390 degrees of freedom
## Multiple R-squared:  0.668,Adjusted R-squared:  0.667
## F-statistic:  786 on 1 and 390 DF,  p-value: <2e-16
```

```r
summary(l5)
```

```
##
## Call:
## lm(formula = mpg ~ poly(horsepower, degree = 5), data = Auto)
##
## Residuals:
##     Min      1Q  Median      3Q     Max
## -15.433  -2.529  -0.293   2.175  15.973
##
## Coefficients:
##                               Estimate Std. Error t value
## (Intercept)                     23.446      0.218  107.31
## poly(horsepower, degree = 5)1 -120.138      4.326  -27.77
## poly(horsepower, degree = 5)2   44.090      4.326   10.19
```

```
## poly(horsepower, degree = 5)3   -3.949      4.326   -0.91
## poly(horsepower, degree = 5)4   -5.188      4.326   -1.20
## poly(horsepower, degree = 5)5   13.272      4.326    3.07
##                                Pr(>|t|)
## (Intercept)                      <2e-16 ***
## poly(horsepower, degree = 5)1   <2e-16 ***
## poly(horsepower, degree = 5)2   <2e-16 ***
## poly(horsepower, degree = 5)3   0.3619
## poly(horsepower, degree = 5)4   0.2312
## poly(horsepower, degree = 5)5   0.0023 **
## ---
## Signif. codes:
## 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 4.33 on 386 degrees of freedom
## Multiple R-squared:  0.697,Adjusted R-squared:  0.693
## F-statistic:  177 on 5 and 386 DF,  p-value: <2e-16
```

```r
summary(l6)
```

```
##
## Call:
## lm(formula = mpg ~ poly(horsepower, degree = 6), data = Auto)
##
## Residuals:
##     Min      1Q  Median      3Q     Max
## -15.595  -2.571  -0.269   2.209  15.362
##
## Coefficients:
##                                Estimate Std. Error t value
## (Intercept)                      23.446      0.218  107.72
## poly(horsepower, degree = 6)1 -120.138      4.310  -27.88
## poly(horsepower, degree = 6)2   44.090      4.310   10.23
## poly(horsepower, degree = 6)3   -3.949      4.310   -0.92
## poly(horsepower, degree = 6)4   -5.188      4.310   -1.20
## poly(horsepower, degree = 6)5   13.272      4.310    3.08
## poly(horsepower, degree = 6)6   -8.546      4.310   -1.98
##                                Pr(>|t|)
## (Intercept)                      <2e-16 ***
## poly(horsepower, degree = 6)1   <2e-16 ***
## poly(horsepower, degree = 6)2   <2e-16 ***
## poly(horsepower, degree = 6)3   0.3601
## poly(horsepower, degree = 6)4   0.2294
## poly(horsepower, degree = 6)5   0.0022 **
## poly(horsepower, degree = 6)6   0.0481 *
## ---
## Signif. codes:
## 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

```
##
## Residual standard error: 4.31 on 385 degrees of freedom
## Multiple R-squared:   0.7,Adjusted R-squared:  0.695
## F-statistic:  150 on 6 and 385 DF,  p-value: <2e-16
```

```r
AIC(l1, l2, llog, l5, l6)
```

```
##      df  AIC
## l1    3 2363
## l2    4 2274
## llog  3 2296
## l5    7 2269
## l6    8 2267
```

```r
BIC(l1, l2, llog, l5, l6)
```

```
##      df  BIC
## l1    3 2375
## l2    4 2290
## llog  3 2308
## l5    7 2296
## l6    8 2298
```

```r
anova(l1, l2)
```

```
## Analysis of Variance Table
##
## Model 1: mpg ~ horsepower
## Model 2: mpg ~ poly(horsepower, degree = 2)
##   Res.Df  RSS Df Sum of Sq   F Pr(>F)
## 1    390 9386
## 2    389 7442  1      1944 102 <2e-16 ***
## ---
## Signif. codes:
## 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

```r
anova(l1, l5)
```

```
## Analysis of Variance Table
##
## Model 1: mpg ~ horsepower
## Model 2: mpg ~ poly(horsepower, degree = 5)
##   Res.Df  RSS Df Sum of Sq    F Pr(>F)
## 1    390 9386
## 2    386 7223  4      2163 28.9 <2e-16 ***
## ---
## Signif. codes:
## 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

```r
anova(l1, l6)
```

```
## Analysis of Variance Table
##
## Model 1: mpg ~ horsepower
## Model 2: mpg ~ poly(horsepower, degree = 6)
##   Res.Df  RSS Df Sum of Sq    F Pr(>F)
## 1    390 9386
## 2    385 7150  5      2236 24.1 <2e-16 ***
## ---
## Signif. codes:
## 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

```
anova(l5, l6)
```

```
## Analysis of Variance Table
##
## Model 1: mpg ~ poly(horsepower, degree = 5)
## Model 2: mpg ~ poly(horsepower, degree = 6)
##   Res.Df  RSS Df Sum of Sq    F Pr(>F)
## 1    386 7223
## 2    385 7150  1        73 3.93  0.048 *
## ---
## Signif. codes:
## 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

4.3 Линейная регрессия (Университеты)

```
read_chunk("REG.R")
```

```
library(MASS)
library(lattice)
library(latticeExtra)
library(latticist)

## Loading required package: vcd
## Loading required package: grid
##
## Attaching package: 'vcd'
##
## The following object is masked from 'package:latticeExtra':
##
##    rootogram

df <- read.csv2(file = "I.csv")
```

```r
# Я установил пакет latticist, чтобы вдоволь налюбоваться на университеты
# Я решил, что переменных слишком много и оставил
# только по одной из каждого класса
# Например, количество вечерников и очников ---
# явно характеристики одного и того же, поэтому оставим только одну из них
# Мы же помним, что брать сильно кореллированые признаки в модель ---
# дурной тон?)
#
# Итааааааак, барабанная дробь, я решил оставить:
# PPIND - фактор, 1 - Государственный, 2 - Частный университет.
#
# AVRCOMB - средний средний балл на вступительных экзаменах
# (SAT, вроде нашего ЕГЭ).
#
# NEW10 - Это то, что будем аппроксимровать, задание у нас такое
# Это процент свежезачисленных студентов-отличников
# (Процент среди поступивших, тех, кто в H.S. входил в 10% лучших)
# В оригинале ""Pct. new students from top 10% of H.S. class""
#
# FULLTIME - Количество студентов-очников
#
# IN_STATE - Плата за обучение для местных
#
# ROOM - Плата за койку в общаге
#
# ADD_FEE - Дополнительные поборы (сверх платы за обучение,
# койку и учебные материалы)
#
# PH_D - Процент кандидатов наук среди педагогического состава.
#
# GRADUAT - Процент выпустившихся. Гы-гы=)
#
# SAL_FULL - Средняя зарплата полного профессора (full professor).
# NUM_FULL - Количетво этих самых полных профессоров
#
#
# Теперь нам надо обрезать и подправить
# исходный датафрейм и скормить его latticist.

# latticist(df)

# Отобрали признаки
df <- subset(df, select = c(PPIND, AVRCOMB, NEW10, FULLTIME,
                            IN_STATE, ROOM, ADD_FEE,
                            PH_D, GRADUAT, SAL_FULL, NUM_FULL))

# Сконвертировали тип Университета в фактор,
# так и вывод красивее, и в модели будет удобнее интерпретировать
```

```r
df$PPIND <- factor(df$PPIND, labels = c("Public", "Private"))
df <- na.exclude(df)


splom(df, groups = df$PPIND)
```

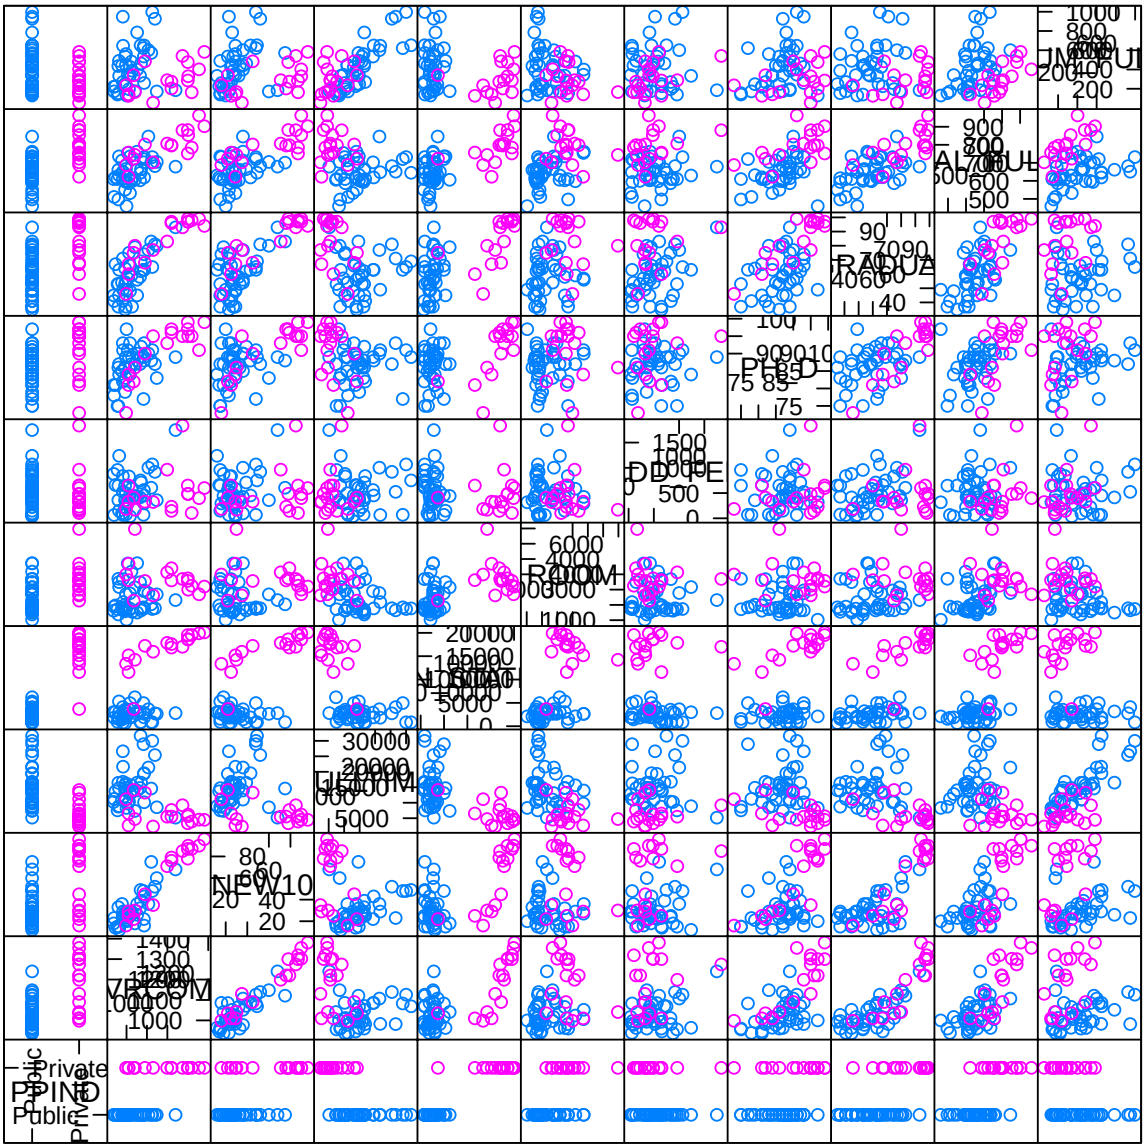

Scatter Plot Matrix

```r
# Гвардия, в бой!
# latticist(df)

# На этом графике хорошо видно, что данные неоднородны.
# Нам надо будет выбрать, кого оставить ---
# частные или государственные университеты.
# Я оставлю государственные, потому что их больше.
marginal.plot(df, data = df,
              groups = PPIND, auto.key = list(lines = TRUE,
```

```
                                                    title = "PPIND",
                                                    cex.title = 1,
                                                    columns = 2))
```

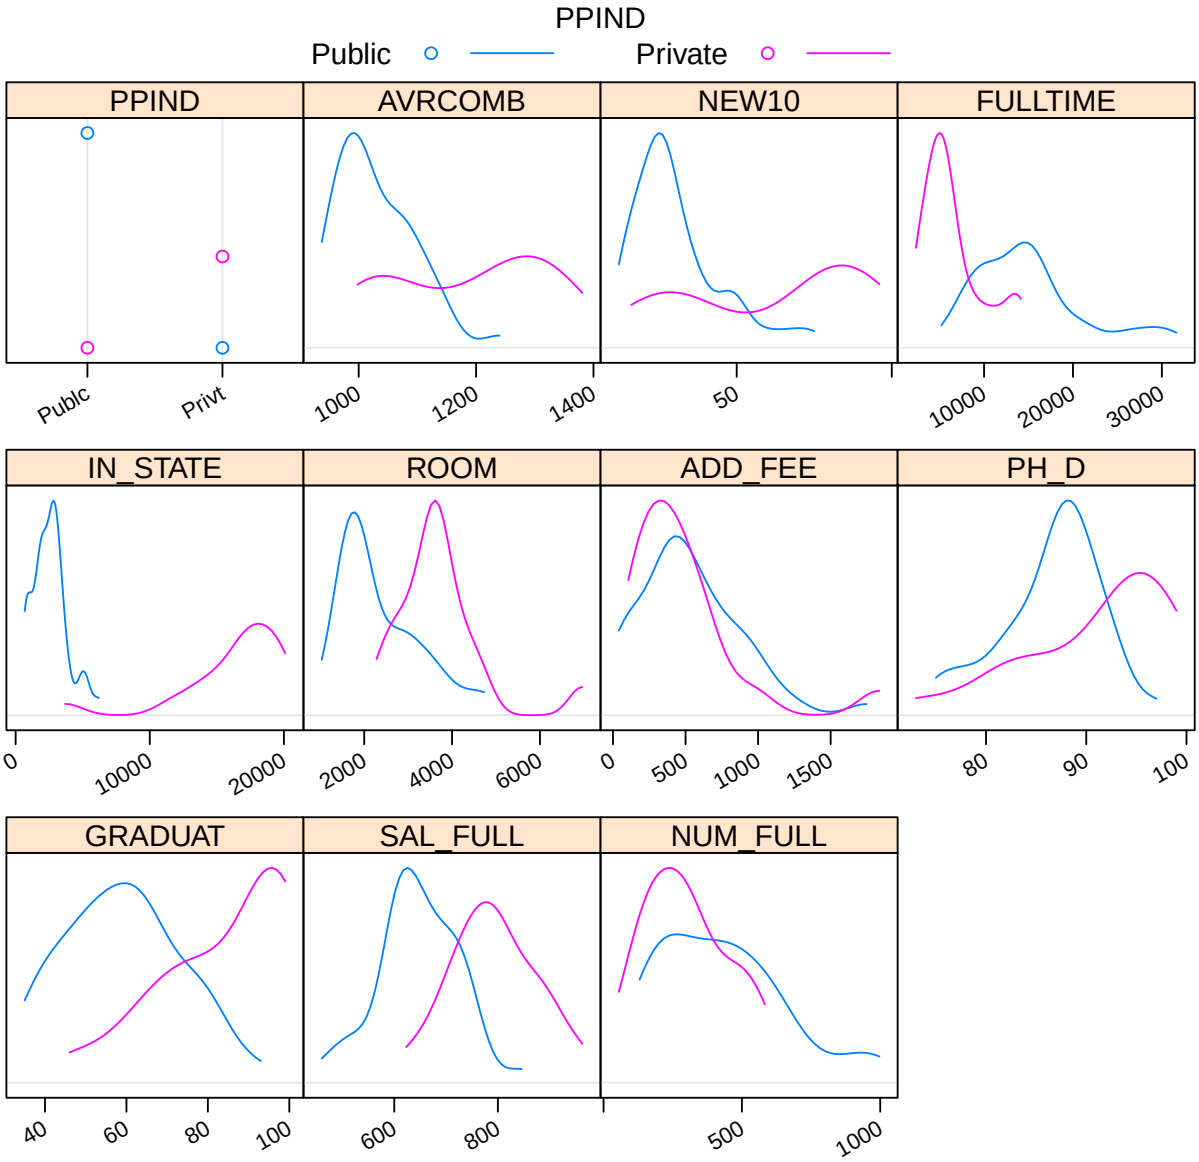


```
df.pub <- subset(df, PPIND == "Public")
# Теперь посмотрим на нормальность,
# может, что-то стоит прологарифмировать?...
# latticist(df.pub)
# Подозрение падает на денежные признаки. Они часто логнормальны.

marginal.plot(subset(df.pub, select = c(ADD_FEE, ROOM, IN_STATE, SAL_FULL)))
```

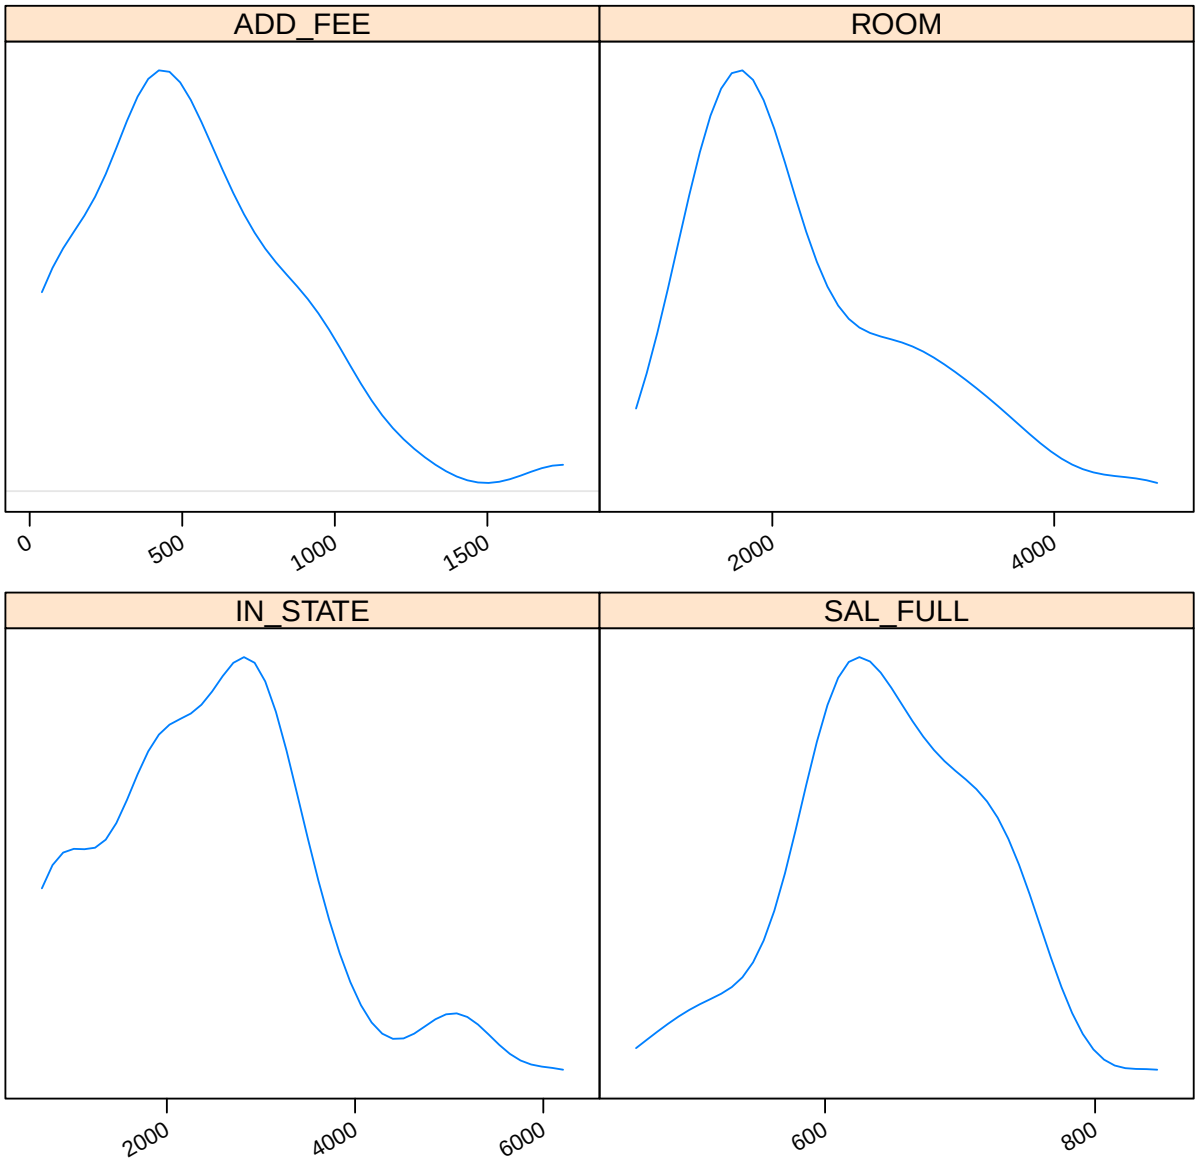


```
marginal.plot(log(subset(df.pub, select = c(ADD_FEE, ROOM, IN_STATE, SAL_FULL))))
```

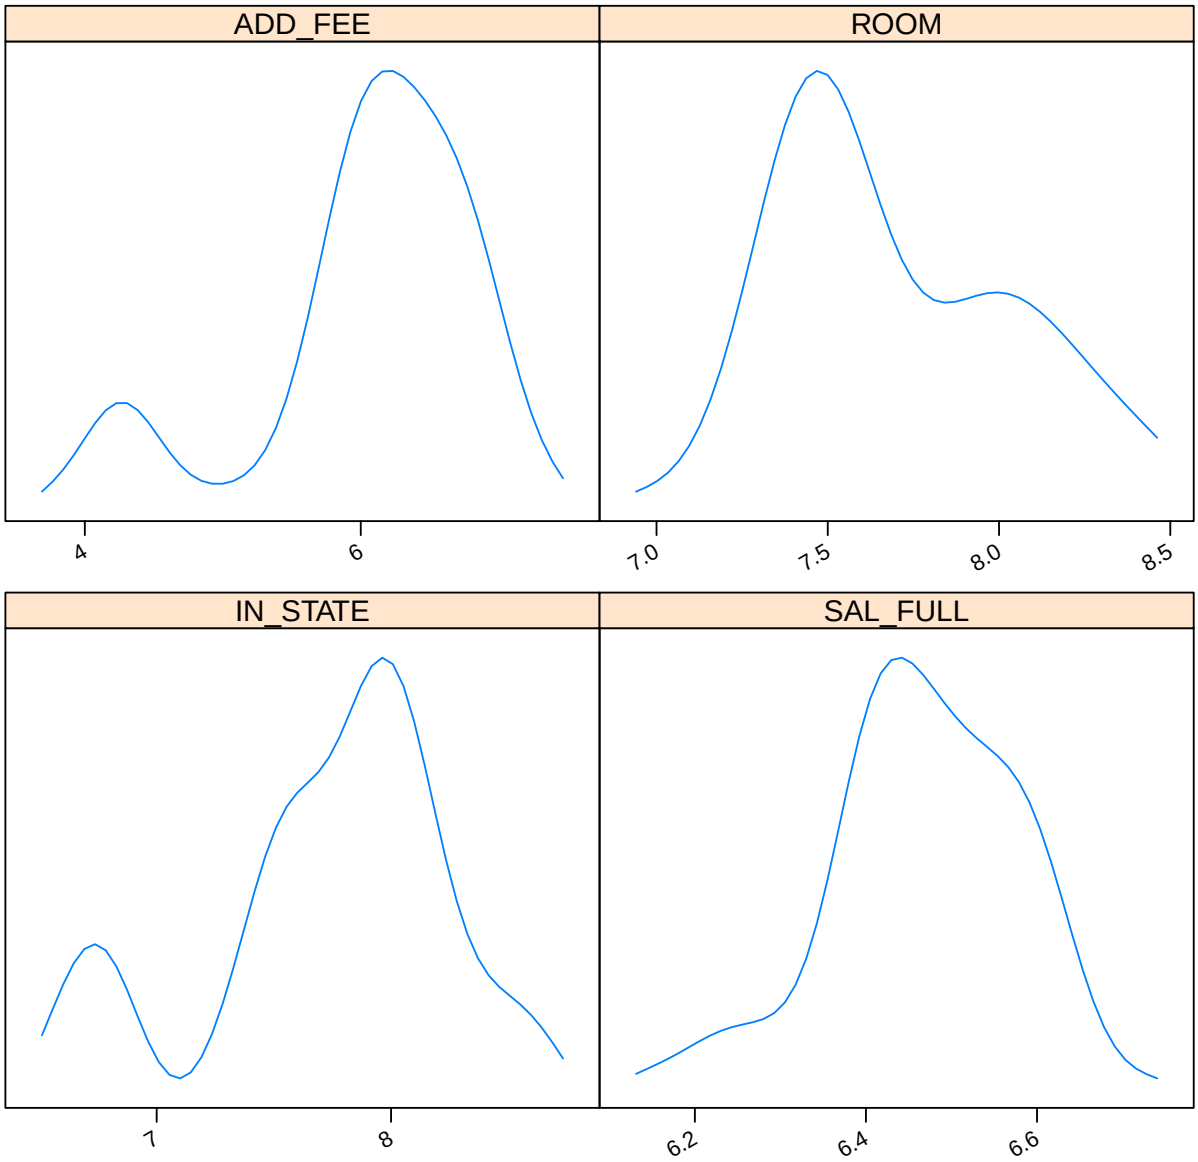


```
# После логарифмирования появилась мультимодальность,
# хотя распределения стали на вид немного более симметричными.
# Я все-таки хочу оставить логарифмирование, потому что это денежные признаки
# Но потом мы проверим и без него

# Итого
fit1 <- lm(NEW10 ~ AVRCOMB + FULLTIME +
           log(IN_STATE) + log(ROOM) + log(ADD_FEE) + log(SAL_FULL) +
           PH_D + GRADUAT  + NUM_FULL, data = df.pub)
summary(fit1)

##
## Call:
## lm(formula = NEW10 ~ AVRCOMB + FULLTIME + log(IN_STATE) + log(ROOM) +
##     log(ADD_FEE) + log(SAL_FULL) + PH_D + GRADUAT + NUM_FULL,
```

```
##     data = df.pub)
##
## Residuals:
##    Min     1Q Median     3Q    Max
## -22.77  -3.41   1.11   3.59  15.07
##
## Coefficients:
##                Estimate Std. Error t value Pr(>|t|)
## (Intercept)   -4.40e+01   8.49e+01   -0.52   0.6083
## AVRCOMB        1.47e-01   2.82e-02    5.20  1.3e-05 ***
## FULLTIME      -2.46e-04   3.80e-04   -0.65   0.5223
## log(IN_STATE) -9.06e+00   2.65e+00   -3.42   0.0018 **
## log(ROOM)     -4.01e+00   4.08e+00   -0.98   0.3338
## log(ADD_FEE)  -3.65e+00   1.63e+00   -2.24   0.0325 *
## log(SAL_FULL)  1.11e+01   1.46e+01    0.76   0.4509
## PH_D          -4.98e-01   2.84e-01   -1.75   0.0897 .
## GRADUAT        2.65e-01   1.47e-01    1.80   0.0817 .
## NUM_FULL       1.22e-02   1.17e-02    1.05   0.3043
## ---
## Signif. codes:
## 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 7.75 on 30 degrees of freedom
## Multiple R-squared:  0.787,Adjusted R-squared:  0.724
## F-statistic: 12.3 on 9 and 30 DF,  p-value: 6.86e-08

# Имеем --- отличники прекрасно сдают экзамены и поступают туда,
# где меньше надо платить, меньше поборов, меньше кандидатов (sic!)
# и больше процент успешно закончивших.
#
# На самом деле, это несодержательно.
# AVRCOMB --- абсолютно не нужен нам.
# И так понятно, что отличники там, где отличники.
# Если мы хотим получить действительно информативную модель и
# нетривиальные выводы, то из предикторов AVRCOMB
# имеет смысл убрать, иначе трактовка регрессии будет тавтологией

fit2 <- lm(NEW10 ~ FULLTIME +
           log(IN_STATE) + log(ROOM) + log(ADD_FEE) + log(SAL_FULL) +
           PH_D + GRADUAT + NUM_FULL, data = df.pub)
summary(fit2)

##
## Call:
## lm(formula = NEW10 ~ FULLTIME + log(IN_STATE) + log(ROOM) + log(ADD_FEE) +
##     log(SAL_FULL) + PH_D + GRADUAT + NUM_FULL, data = df.pub)
##
## Residuals:
```

```
##     Min      1Q  Median      3Q     Max
## -22.749  -5.841   0.533   5.365  23.062
##
## Coefficients:
##                Estimate Std. Error t value Pr(>|t|)
## (Intercept)    4.53e+01   1.13e+02    0.40  0.69069
## FULLTIME      -3.02e-04   5.15e-04   -0.59  0.56136
## log(IN_STATE) -1.31e+01   3.43e+00   -3.83  0.00059 ***
## log(ROOM)     -2.31e+00   5.52e+00   -0.42  0.67830
## log(ADD_FEE)  -4.26e+00   2.20e+00   -1.93  0.06226 .
## log(SAL_FULL)  1.67e+01   1.97e+01    0.85  0.40380
## PH_D          -2.90e-01   3.82e-01   -0.76  0.45296
## GRADUAT        7.37e-01   1.57e-01    4.70    5e-05 ***
## NUM_FULL       1.92e-02   1.58e-02    1.21  0.23418
## ---
## Signif. codes:
## 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 10.5 on 31 degrees of freedom
## Multiple R-squared:  0.596,Adjusted R-squared:  0.491
## F-statistic: 5.71 on 8 and 31 DF,  p-value: 0.000172

# Уже на что-то похоже.
# Поступают туда, где дешевле, где больше шанс выпуститься и меньше поборов.

# Попробуем уменьшить число признаков. Вручную по t-test и по Акаике
fit2.manual <- lm(NEW10 ~ log(IN_STATE) + log(ADD_FEE) + GRADUAT, data = df.pub)
summary(fit2.manual)

##
## Call:
## lm(formula = NEW10 ~ log(IN_STATE) + log(ADD_FEE) + GRADUAT,
##     data = df.pub)
##
## Residuals:
##    Min     1Q Median     3Q    Max
## -26.23  -5.18  -0.44   6.80  19.58
##
## Coefficients:
##               Estimate Std. Error t value Pr(>|t|)
## (Intercept)    113.062     28.269    4.00  0.00030 ***
## log(IN_STATE)  -13.187      3.228   -4.09  0.00023 ***
## log(ADD_FEE)    -4.830      2.149   -2.25  0.03080 *
## GRADUAT          0.819      0.138    5.95  8.1e-07 ***
## ---
## Signif. codes:
## 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
```

```
## Residual standard error: 10.5 on 36 degrees of freedom
## Multiple R-squared:  0.53,Adjusted R-squared:  0.491
## F-statistic: 13.5 on 3 and 36 DF,  p-value: 4.56e-06

fit2.aic <- stepAIC(fit2)

## Start:  AIC=196.1
## NEW10 ~ FULLTIME + log(IN_STATE) + log(ROOM) + log(ADD_FEE) +
##     log(SAL_FULL) + PH_D + GRADUAT + NUM_FULL
##
##                 Df Sum of Sq  RSS AIC
## - log(ROOM)      1        19 3451 194
## - FULLTIME       1        38 3470 194
## - PH_D           1        64 3496 195
## - log(SAL_FULL)  1        79 3511 195
## - NUM_FULL       1       163 3595 196
## <none>                       3432 196
## - log(ADD_FEE)   1       414 3846 199
## - log(IN_STATE)  1      1623 5055 210
## - GRADUAT        1      2450 5883 216
##
## Step:  AIC=194.3
## NEW10 ~ FULLTIME + log(IN_STATE) + log(ADD_FEE) + log(SAL_FULL) +
##     PH_D + GRADUAT + NUM_FULL
##
##                 Df Sum of Sq  RSS AIC
## - FULLTIME       1        37 3488 193
## - log(SAL_FULL)  1        60 3511 193
## - PH_D           1        61 3513 193
## <none>                       3451 194
## - NUM_FULL       1       194 3645 194
## - log(ADD_FEE)   1       451 3903 197
## - log(IN_STATE)  1      1729 5181 209
## - GRADUAT        1      2629 6081 215
##
## Step:  AIC=192.7
## NEW10 ~ log(IN_STATE) + log(ADD_FEE) + log(SAL_FULL) + PH_D +
##     GRADUAT + NUM_FULL
##
##                 Df Sum of Sq  RSS AIC
## - PH_D           1        43 3531 191
## - log(SAL_FULL)  1        65 3554 192
## <none>                       3488 193
## - NUM_FULL       1       250 3739 194
## - log(ADD_FEE)   1       433 3921 195
## - log(IN_STATE)  1      1702 5190 207
## - GRADUAT        1      2592 6081 213
##
```

```
## Step:  AIC=191.2
## NEW10 ~ log(IN_STATE) + log(ADD_FEE) + log(SAL_FULL) + GRADUAT +
##     NUM_FULL
##
##                 Df Sum of Sq  RSS AIC
## - log(SAL_FULL)  1        60 3591 190
## <none>                      3531 191
## - NUM_FULL       1       212 3743 192
## - log(ADD_FEE)   1       458 3989 194
## - log(IN_STATE)  1      1724 5255 205
## - GRADUAT        1      2551 6082 211
##
## Step:  AIC=189.9
## NEW10 ~ log(IN_STATE) + log(ADD_FEE) + GRADUAT + NUM_FULL
##
##                 Df Sum of Sq  RSS AIC
## <none>                      3591 190
## - NUM_FULL       1       397 3988 192
## - log(ADD_FEE)   1       446 4037 193
## - log(IN_STATE)  1      1664 5255 203
## - GRADUAT        1      3291 6882 214
```

```r
summary(fit2.aic)
```

```
##
## Call:
## lm(formula = NEW10 ~ log(IN_STATE) + log(ADD_FEE) + GRADUAT +
##     NUM_FULL, data = df.pub)
##
## Residuals:
##     Min      1Q  Median      3Q     Max
## -22.987  -5.665  -0.508   5.308  23.992
##
## Coefficients:
##                Estimate Std. Error t value Pr(>|t|)
## (Intercept)   102.45261   27.73302    3.69  0.00075 ***
## log(IN_STATE) -12.57406    3.12200   -4.03  0.00029 ***
## log(ADD_FEE)   -4.34406    2.08263   -2.09  0.04435 *
## GRADUAT         0.76556    0.13517    5.66  2.1e-06 ***
## NUM_FULL        0.01423    0.00723    1.97  0.05702 .
## ---
## Signif. codes:
## 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 10.1 on 35 degrees of freedom
## Multiple R-squared:  0.577,Adjusted R-squared:  0.528
## F-statistic: 11.9 on 4 and 35 DF,  p-value: 3.23e-06
```

```r
# Акаике предлагает оставить признак NUM_FULL.
```

```r
# Отличники поступают туда еще, где народу побольше.

# Посравниваю-ка я модели...

AIC(fit2.manual, fit2.aic)

##              df   AIC
## fit2.manual  5 307.6
## fit2.aic     6 305.4

# Неудивительно, потому что fit.aic построена по stepAIC()

anova(fit2.manual, fit2.aic)

## Analysis of Variance Table
##
## Model 1: NEW10 ~ log(IN_STATE) + log(ADD_FEE) + GRADUAT
## Model 2: NEW10 ~ log(IN_STATE) + log(ADD_FEE) + GRADUAT + NUM_FULL
##   Res.Df  RSS Df Sum of Sq    F Pr(>F)
## 1     36 3988
## 2     35 3591  1       397 3.87  0.057 .
## ---
## Signif. codes:
## 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1

# Посмотрим на корреляции признаков, возможно,
# некоторые признаки захочется удалить,
# потому что они сильно коррелируют с другими
cor(fit2.aic$model)

##                  NEW10 log(IN_STATE) log(ADD_FEE) GRADUAT
## NEW10          1.0000      -0.25001      0.11170  0.5450
## log(IN_STATE) -0.2500       1.00000     -0.15425  0.2645
## log(ADD_FEE)   0.1117      -0.15425      1.00000  0.4106
## GRADUAT        0.5450       0.26450      0.41065  1.0000
## NUM_FULL       0.3517      -0.02384     -0.02152  0.1516
##                NUM_FULL
## NEW10          0.35167
## log(IN_STATE) -0.02384
## log(ADD_FEE)  -0.02152
## GRADUAT        0.15156
## NUM_FULL       1.00000

levelplot(cor(fit2.aic$model)^2,
          par.settings = list(regions = list(col = colorRampPalette(grey(1:0)))),
          scales = list(x = list(rot = 90)),
          xlab = "", ylab = "")
```

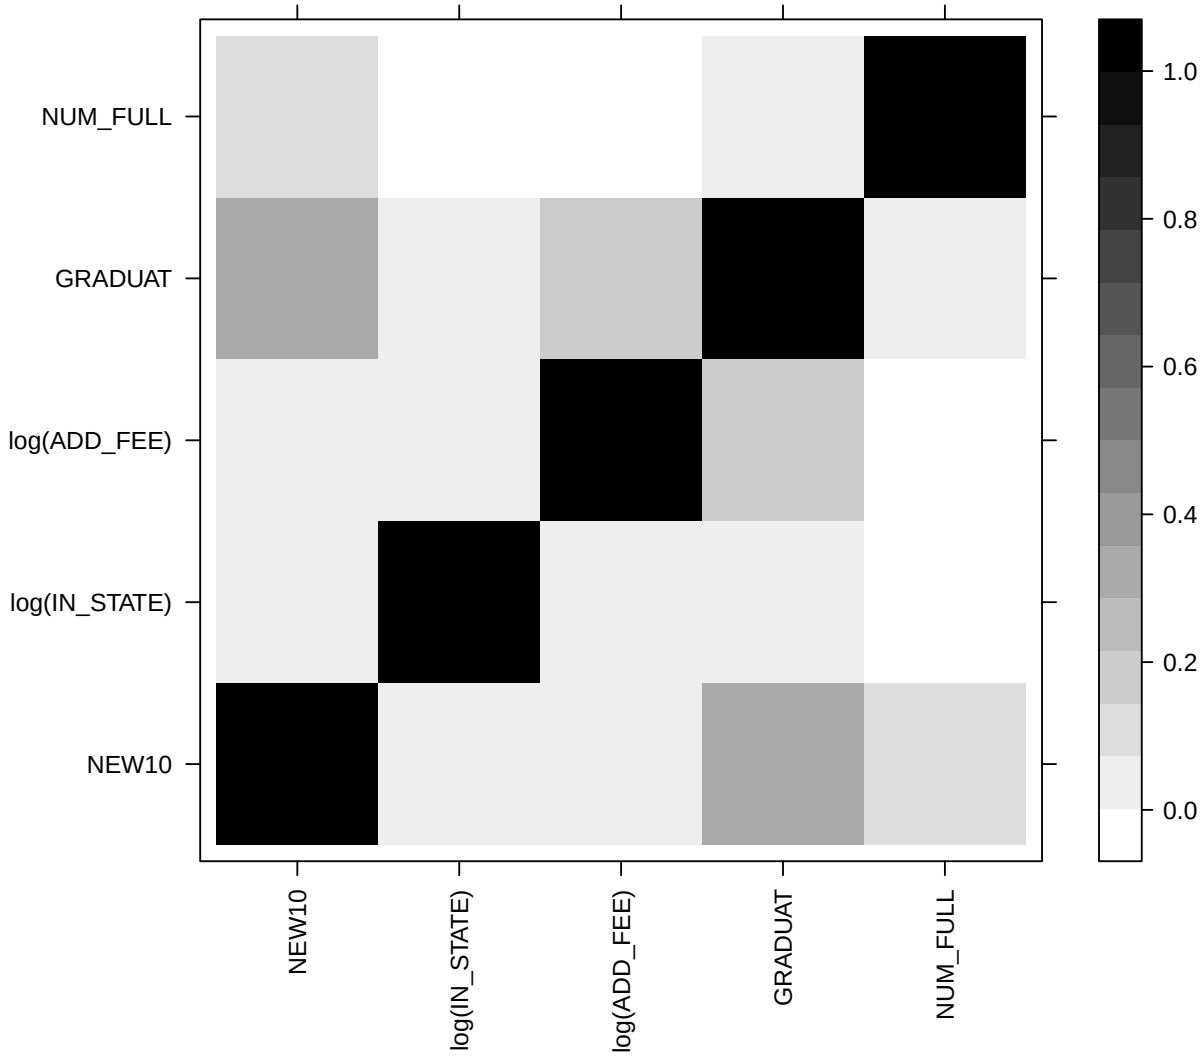


```
summary(fit2.aic)

##
## Call:
## lm(formula = NEW10 ~ log(IN_STATE) + log(ADD_FEE) + GRADUAT +
##     NUM_FULL, data = df.pub)
##
## Residuals:
##     Min      1Q  Median      3Q     Max
## -22.987  -5.665  -0.508   5.308  23.992
##
## Coefficients:
##                Estimate Std. Error t value Pr(>|t|)
## (Intercept)   102.45261   27.73302    3.69  0.00075 ***
## log(IN_STATE) -12.57406    3.12200   -4.03  0.00029 ***
```

```
## log(ADD_FEE)   -4.34406    2.08263   -2.09  0.04435 *
## GRADUAT         0.76556    0.13517    5.66  2.1e-06 ***
## NUM_FULL        0.01423    0.00723    1.97  0.05702 .
## ---
## Signif. codes:
## 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 10.1 on 35 degrees of freedom
## Multiple R-squared:  0.577,Adjusted R-squared:  0.528
## F-statistic: 11.9 on 4 and 35 DF,  p-value: 3.23e-06

# ADD_FEE и NUM_FULL у меня на большом подозрении, особенно первый.
# Они малозначимы и сильно коррелируют с GRADUAT,
# велика вероятность, что они мусорные
# Используем CV сравнение train-test слишком неустойчиво себя ведет
l <- update(fit2.aic, . ~ . - log(ADD_FEE) - NUM_FULL)

library(e1071)
tune(lm, fit2.aic$call$formula, data =  df.pub,
     tunecontrol = tune.control(sampling = "cross", cross = 35))

##
## Error estimation of 'lm' using 35-fold cross validation: 108.1

tune(lm, l$call$formula, data =  df.pub,
     tunecontrol = tune.control(sampling = "cross", cross = 35))

##
## Error estimation of 'lm' using 35-fold cross validation: 140.6

# Вывод --- все-таки выкидывать не стоило


# Попробуем нелогарифмировать признаки и сравним модели
fit.nolog <- lm(NEW10 ~ IN_STATE + ADD_FEE + GRADUAT + NUM_FULL, data = df.pub)
summary(fit.nolog)

##
## Call:
## lm(formula = NEW10 ~ IN_STATE + ADD_FEE + GRADUAT + NUM_FULL,
##     data = df.pub)
##
## Residuals:
##     Min      1Q  Median      3Q     Max
## -24.091  -4.681   0.547   3.576  24.793
##
## Coefficients:
##             Estimate Std. Error t value Pr(>|t|)
## (Intercept) -1.86698    7.50975   -0.25  0.80512
```

```
## IN_STATE    -0.00528    0.00142   -3.73  0.00069 ***
## ADD_FEE     -0.00599    0.00549   -1.09  0.28269
## GRADUAT      0.72609    0.14410    5.04  1.4e-05 ***
## NUM_FULL     0.01533    0.00746    2.06  0.04738 *
## ---
## Signif. codes:
## 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 10.4 on 35 degrees of freedom
## Multiple R-squared:  0.55,Adjusted R-squared:  0.498
## F-statistic: 10.7 on 4 and 35 DF,  p-value: 9.13e-06
```

```
AIC(fit.nolog, fit2.aic)
```

```
##           df   AIC
## fit.nolog  6 307.9
## fit2.aic   6 305.4
```

```
# Как видно, прологарифмировали мы все-таки не зря
```

4.3.1 Advertising, окончательный результат

```
read_chunk("Advertising.R")
```

```
library(lattice)
library(latticeExtra)
library(MASS)
library(e1071)

Advertising <- read.csv("Advertising.csv")
Advertising$X <- NULL


l <- lm(Sales ~ TV + Radio + Newspaper, data = Advertising)
li <- lm(Sales ~ (TV + Radio + Newspaper)^2, data = Advertising)
ltvradio <- lm(Sales ~ TV + Radio + Newspaper + TV : Radio, data = Advertising)

laic <- stepAIC(li)
```

```
## Start:  AIC=-18.59
## Sales ~ (TV + Radio + Newspaper)^2
##
##                    Df Sum of Sq RSS   AIC
## - Radio:Newspaper  1         0 170 -20.4
## <none>                        170 -18.6
## - TV:Newspaper     1         4 174 -15.5
```

```
## - TV:Radio         1       350 520 203.0
##
## Step:  AIC=-20.36
## Sales ~ TV + Radio + Newspaper + TV:Radio + TV:Newspaper
##
##                Df Sum of Sq RSS   AIC
## <none>                      170 -20.4
## - TV:Newspaper  1         4 174 -17.5
## - TV:Radio      1       353 523 202.2
```

```r
summary(laic)
```

```
##
## Call:
## lm(formula = Sales ~ TV + Radio + Newspaper + TV:Radio + TV:Newspaper,
##     data = Advertising)
##
## Residuals:
##    Min     1Q Median     3Q    Max
## -5.902 -0.382  0.194  0.574  1.484
##
## Coefficients:
##               Estimate Std. Error t value Pr(>|t|)
## (Intercept)   6.54e+00   2.65e-01   24.67   <2e-16 ***
## TV            2.03e-02   1.61e-03   12.67   <2e-16 ***
## Radio         2.02e-02   9.73e-03    2.07    0.039 *
## Newspaper     1.34e-02   6.38e-03    2.10    0.037 *
## TV:Radio      1.14e-03   5.66e-05   20.06   <2e-16 ***
## TV:Newspaper -7.72e-05   3.53e-05   -2.19    0.030 *
## ---
## Signif. codes:
## 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 0.936 on 194 degrees of freedom
## Multiple R-squared:  0.969,Adjusted R-squared:  0.968
## F-statistic: 1.2e+03 on 5 and 194 DF,  p-value: <2e-16
```

```r
xyplot(residuals(laic) ~ fitted(laic))
```

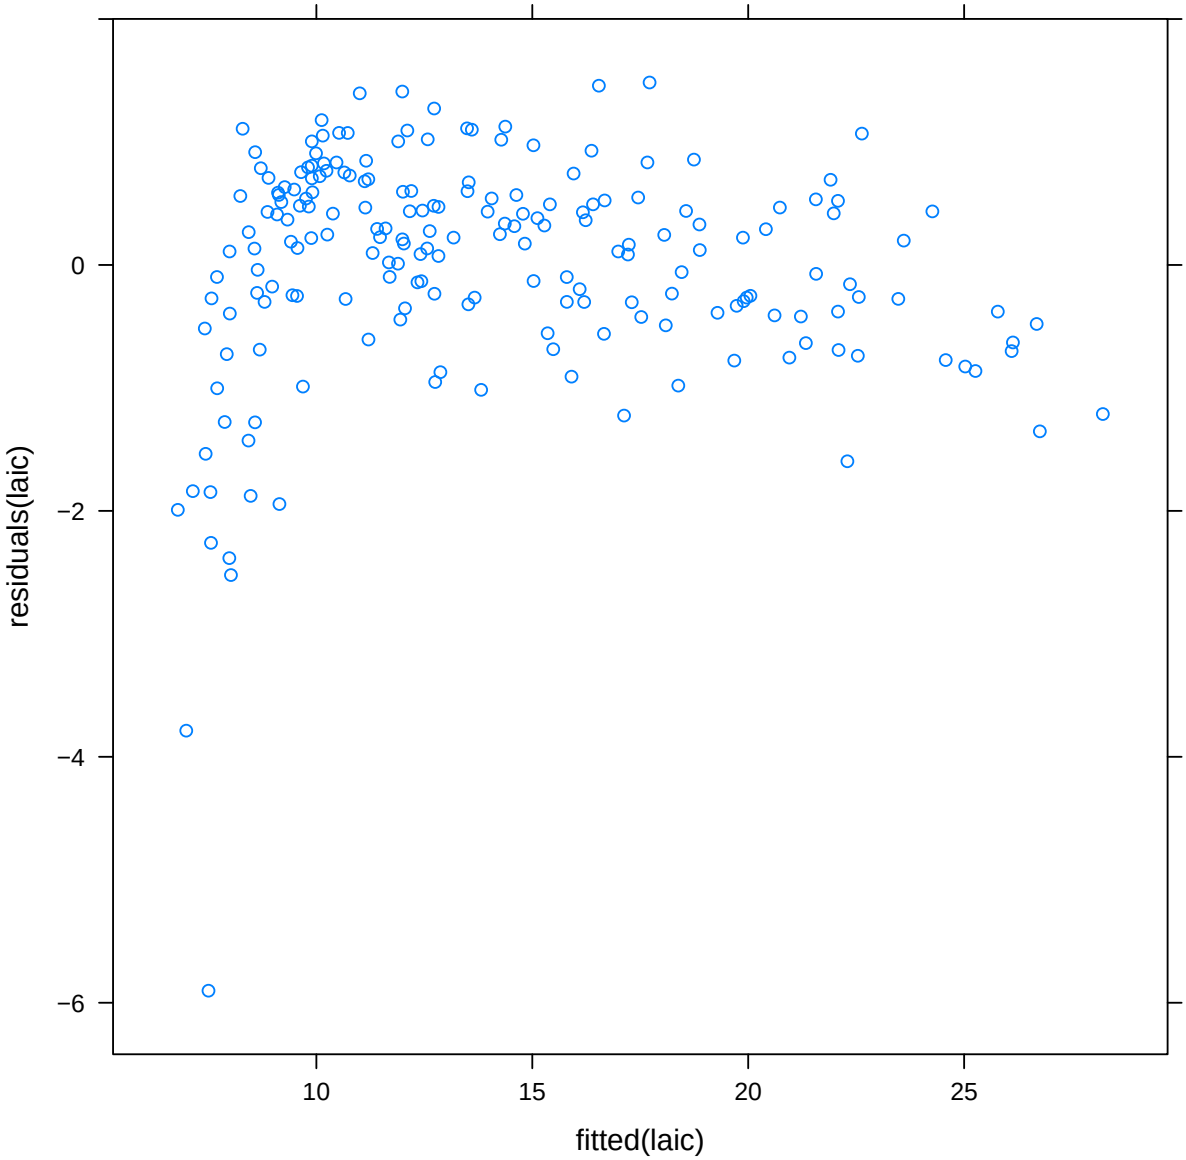


```
lsq <- lm(Sales ~ poly(TV, Radio, Newspaper, degree = 2), data = Advertising)
summary(lsq)

##
## Call:
## lm(formula = Sales ~ poly(TV, Radio, Newspaper, degree = 2),
##     data = Advertising)
##
## Residuals:
##    Min     1Q Median     3Q    Max
## -4.651 -0.294 -0.006  0.383  1.438
##
## Coefficients:
##                                          Estimate
## (Intercept)                               13.9410
```

```
## poly(TV, Radio, Newspaper, degree = 2)1.0.0  53.7303
## poly(TV, Radio, Newspaper, degree = 2)2.0.0  -9.9799
## poly(TV, Radio, Newspaper, degree = 2)0.1.0  40.1048
## poly(TV, Radio, Newspaper, degree = 2)1.1.0 280.3575
## poly(TV, Radio, Newspaper, degree = 2)0.2.0   0.2973
## poly(TV, Radio, Newspaper, degree = 2)0.0.1   0.9437
## poly(TV, Radio, Newspaper, degree = 2)1.0.1 -16.9358
## poly(TV, Radio, Newspaper, degree = 2)0.1.1   5.3188
## poly(TV, Radio, Newspaper, degree = 2)0.0.2   0.1071
##                                             Std. Error
## (Intercept)                                     0.0481
## poly(TV, Radio, Newspaper, degree = 2)1.0.0     0.6258
## poly(TV, Radio, Newspaper, degree = 2)2.0.0     0.6325
## poly(TV, Radio, Newspaper, degree = 2)0.1.0     0.6704
## poly(TV, Radio, Newspaper, degree = 2)1.1.0     9.6532
## poly(TV, Radio, Newspaper, degree = 2)0.2.0     0.6486
## poly(TV, Radio, Newspaper, degree = 2)0.0.1     0.7414
## poly(TV, Radio, Newspaper, degree = 2)1.0.1     8.8441
## poly(TV, Radio, Newspaper, degree = 2)0.1.1    10.9533
## poly(TV, Radio, Newspaper, degree = 2)0.0.2     0.6600
##                                             t value
## (Intercept)                                  290.08
## poly(TV, Radio, Newspaper, degree = 2)1.0.0   85.86
## poly(TV, Radio, Newspaper, degree = 2)2.0.0  -15.78
## poly(TV, Radio, Newspaper, degree = 2)0.1.0   59.82
## poly(TV, Radio, Newspaper, degree = 2)1.1.0   29.04
## poly(TV, Radio, Newspaper, degree = 2)0.2.0    0.46
## poly(TV, Radio, Newspaper, degree = 2)0.0.1    1.27
## poly(TV, Radio, Newspaper, degree = 2)1.0.1   -1.91
## poly(TV, Radio, Newspaper, degree = 2)0.1.1    0.49
## poly(TV, Radio, Newspaper, degree = 2)0.0.2    0.16
##                                             Pr(>|t|)
## (Intercept)                                   <2e-16 ***
## poly(TV, Radio, Newspaper, degree = 2)1.0.0   <2e-16 ***
## poly(TV, Radio, Newspaper, degree = 2)2.0.0   <2e-16 ***
## poly(TV, Radio, Newspaper, degree = 2)0.1.0   <2e-16 ***
## poly(TV, Radio, Newspaper, degree = 2)1.1.0   <2e-16 ***
## poly(TV, Radio, Newspaper, degree = 2)0.2.0    0.647
## poly(TV, Radio, Newspaper, degree = 2)0.0.1    0.205
## poly(TV, Radio, Newspaper, degree = 2)1.0.1    0.057 .
## poly(TV, Radio, Newspaper, degree = 2)0.1.1    0.628
## poly(TV, Radio, Newspaper, degree = 2)0.0.2    0.871
## ---
## Signif. codes:
## 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 0.62 on 190 degrees of freedom
## Multiple R-squared:  0.987,Adjusted R-squared:  0.986
```

```
## F-statistic: 1.54e+03 on 9 and 190 DF,  p-value: <2e-16

xyplot(residuals(lsq) ~ fitted(lsq))
```

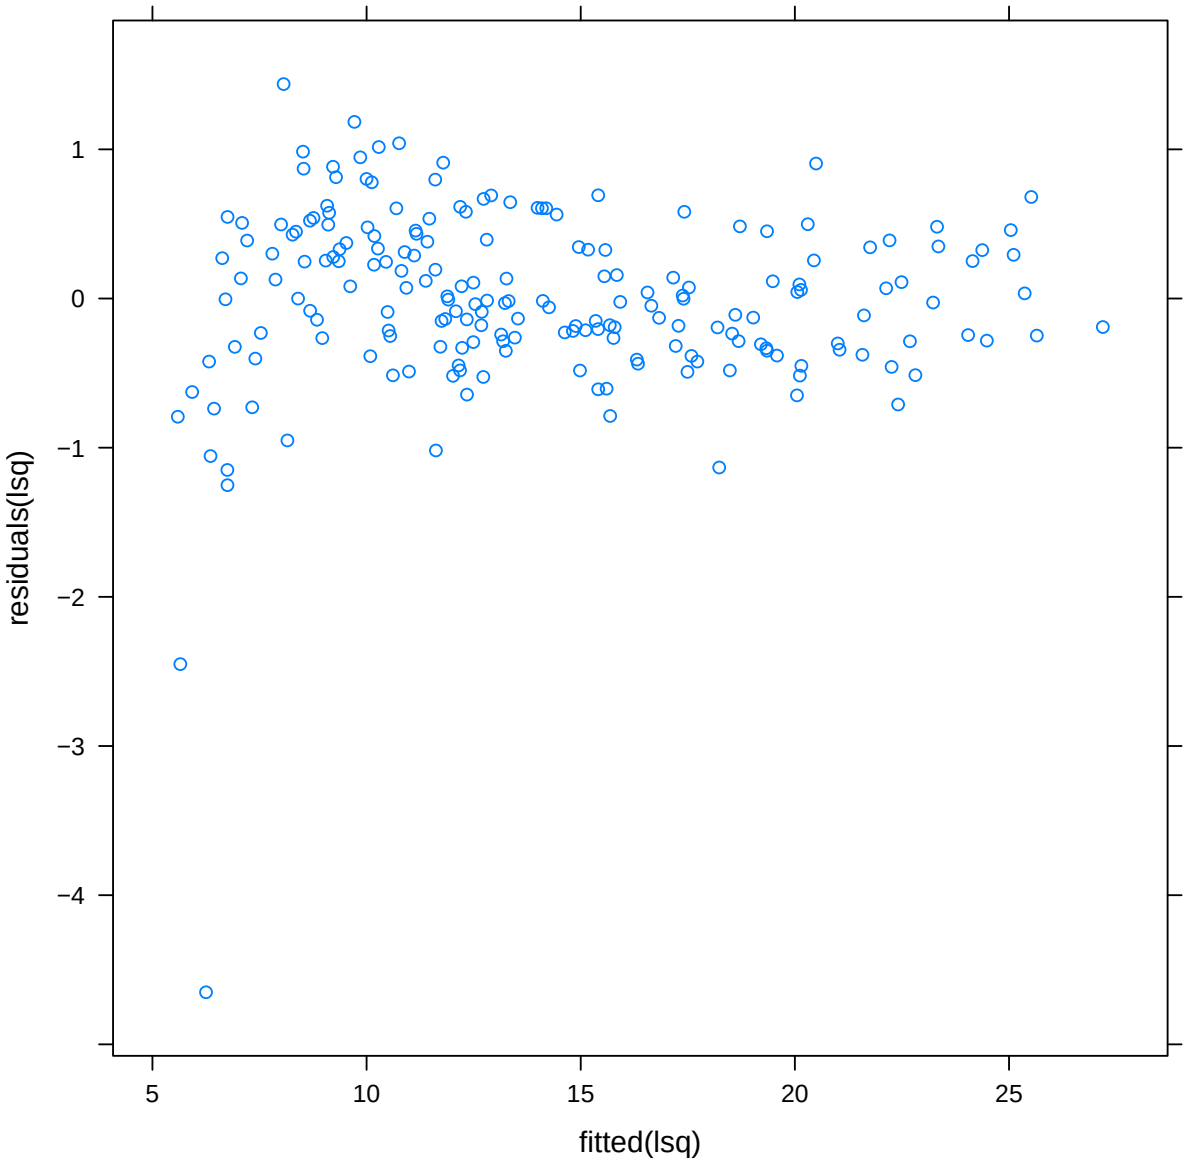


```
lsqaic <- stepAIC(lsq)

## Start:  AIC=-181.3
## Sales ~ poly(TV, Radio, Newspaper, degree = 2)
##
##                                          Df Sum of Sq  RSS
## <none>                                                 73
## - poly(TV, Radio, Newspaper, degree = 2)  9      5344 5417
##                                           AIC
## <none>                                   -181
## - poly(TV, Radio, Newspaper, degree = 2)  662
```

```r
summary(lsqaic)

##
## Call:
## lm(formula = Sales ~ poly(TV, Radio, Newspaper, degree = 2),
##     data = Advertising)
##
## Residuals:
##    Min     1Q Median     3Q    Max
## -4.651 -0.294 -0.006  0.383  1.438
##
## Coefficients:
##                                              Estimate
## (Intercept)                                   13.9410
## poly(TV, Radio, Newspaper, degree = 2)1.0.0  53.7303
## poly(TV, Radio, Newspaper, degree = 2)2.0.0  -9.9799
## poly(TV, Radio, Newspaper, degree = 2)0.1.0  40.1048
## poly(TV, Radio, Newspaper, degree = 2)1.1.0 280.3575
## poly(TV, Radio, Newspaper, degree = 2)0.2.0   0.2973
## poly(TV, Radio, Newspaper, degree = 2)0.0.1   0.9437
## poly(TV, Radio, Newspaper, degree = 2)1.0.1 -16.9358
## poly(TV, Radio, Newspaper, degree = 2)0.1.1   5.3188
## poly(TV, Radio, Newspaper, degree = 2)0.0.2   0.1071
##                                              Std. Error
## (Intercept)                                      0.0481
## poly(TV, Radio, Newspaper, degree = 2)1.0.0      0.6258
## poly(TV, Radio, Newspaper, degree = 2)2.0.0      0.6325
## poly(TV, Radio, Newspaper, degree = 2)0.1.0      0.6704
## poly(TV, Radio, Newspaper, degree = 2)1.1.0      9.6532
## poly(TV, Radio, Newspaper, degree = 2)0.2.0      0.6486
## poly(TV, Radio, Newspaper, degree = 2)0.0.1      0.7414
## poly(TV, Radio, Newspaper, degree = 2)1.0.1      8.8441
## poly(TV, Radio, Newspaper, degree = 2)0.1.1     10.9533
## poly(TV, Radio, Newspaper, degree = 2)0.0.2      0.6600
##                                              t value
## (Intercept)                                   290.08
## poly(TV, Radio, Newspaper, degree = 2)1.0.0   85.86
## poly(TV, Radio, Newspaper, degree = 2)2.0.0  -15.78
## poly(TV, Radio, Newspaper, degree = 2)0.1.0   59.82
## poly(TV, Radio, Newspaper, degree = 2)1.1.0   29.04
## poly(TV, Radio, Newspaper, degree = 2)0.2.0    0.46
## poly(TV, Radio, Newspaper, degree = 2)0.0.1    1.27
## poly(TV, Radio, Newspaper, degree = 2)1.0.1   -1.91
## poly(TV, Radio, Newspaper, degree = 2)0.1.1    0.49
## poly(TV, Radio, Newspaper, degree = 2)0.0.2    0.16
##                                              Pr(>|t|)
## (Intercept)                                    <2e-16 ***
## poly(TV, Radio, Newspaper, degree = 2)1.0.0    <2e-16 ***
```

```
## poly(TV, Radio, Newspaper, degree = 2)2.0.0   <2e-16 ***
## poly(TV, Radio, Newspaper, degree = 2)0.1.0   <2e-16 ***
## poly(TV, Radio, Newspaper, degree = 2)1.1.0   <2e-16 ***
## poly(TV, Radio, Newspaper, degree = 2)0.2.0    0.647
## poly(TV, Radio, Newspaper, degree = 2)0.0.1    0.205
## poly(TV, Radio, Newspaper, degree = 2)1.0.1    0.057 .
## poly(TV, Radio, Newspaper, degree = 2)0.1.1    0.628
## poly(TV, Radio, Newspaper, degree = 2)0.0.2    0.871
## ---
## Signif. codes:
## 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 0.62 on 190 degrees of freedom
## Multiple R-squared:  0.987,Adjusted R-squared:  0.986
## F-statistic: 1.54e+03 on 9 and 190 DF,  p-value: <2e-16

lfinal <- lm(Sales ~ (TV + Radio) ^ 2 + I(TV^2), data = Advertising)
summary(lfinal)

##
## Call:
## lm(formula = Sales ~ (TV + Radio)^2 + I(TV^2), data = Advertising)
##
## Residuals:
##    Min     1Q Median     3Q    Max
## -4.995 -0.297 -0.007  0.380  1.169
##
## Coefficients:
##              Estimate Std. Error t value Pr(>|t|)
## (Intercept)  5.14e+00   1.93e-01   26.66  < 2e-16 ***
## TV           5.09e-02   2.23e-03   22.81  < 2e-16 ***
## Radio        3.52e-02   5.90e-03    5.96  1.2e-08 ***
## I(TV^2)     -1.10e-04   6.89e-06  -15.92  < 2e-16 ***
## TV:Radio     1.08e-03   3.47e-05   31.06  < 2e-16 ***
## ---
## Signif. codes:
## 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 0.624 on 195 degrees of freedom
## Multiple R-squared:  0.986,Adjusted R-squared:  0.986
## F-statistic: 3.43e+03 on 4 and 195 DF,  p-value: <2e-16

xyplot(residuals(lfinal) ~ fitted(lfinal))
```

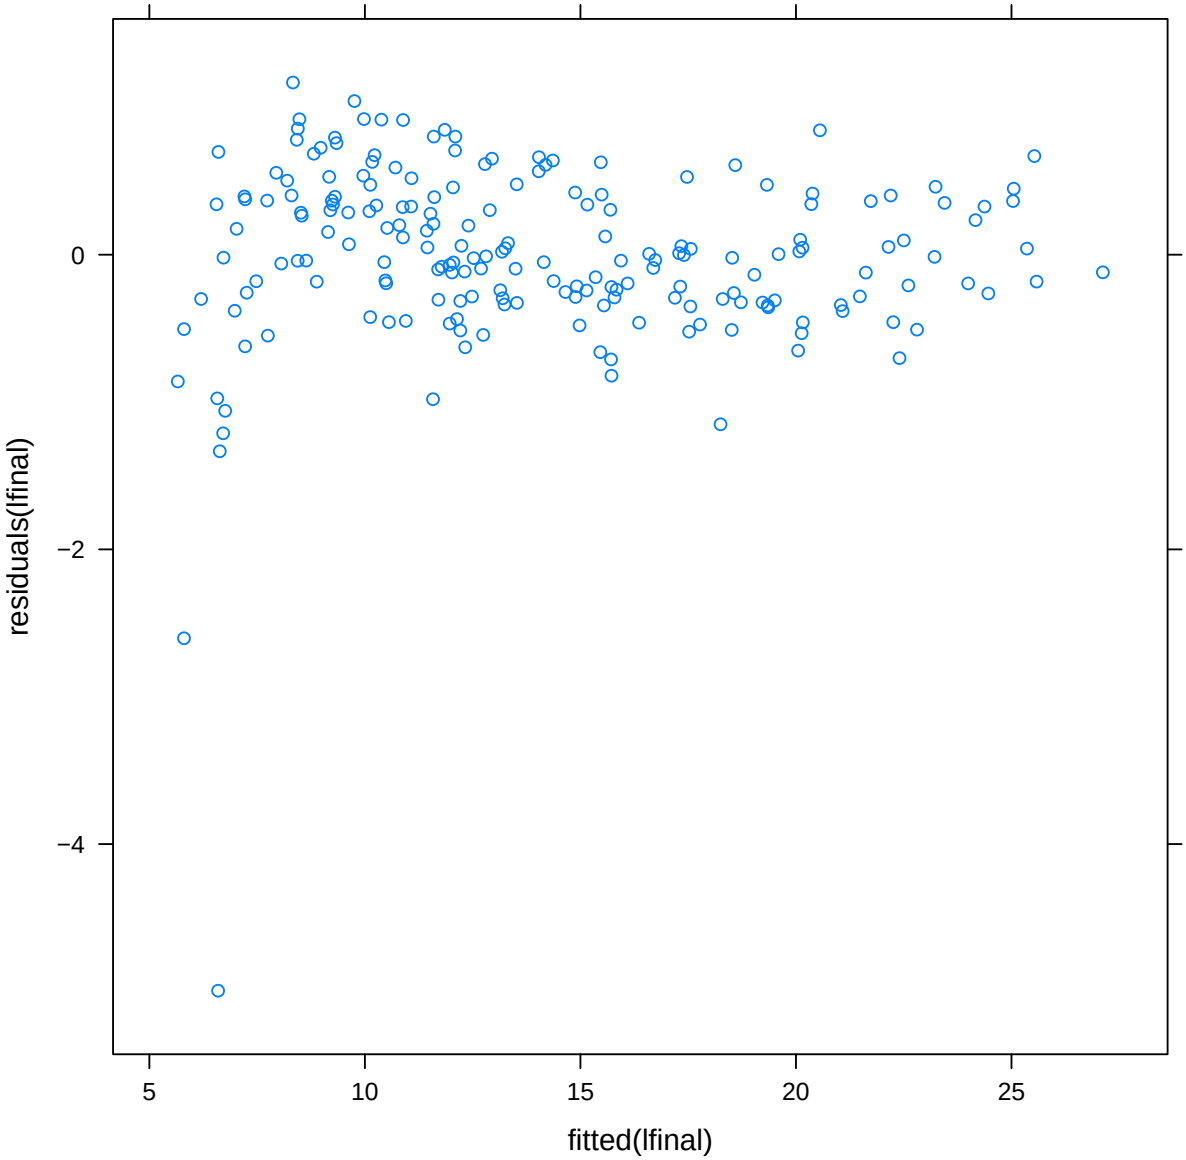


```
tune(lm, lfinal$call$formula, data = Advertising,
     tunecontrol = tune.control(sampling = "fix"))

##
## Error estimation of 'lm' using fixed training/validation set: 0.1949

tune(lm, l$call$formula, data = Advertising,
     tunecontrol = tune.control(sampling = "fix"))

##
## Error estimation of 'lm' using fixed training/validation set: 2.72

tune(lm, ltvradio$call$formula, data = Advertising,
     tunecontrol = tune.control(sampling = "fix"))
```

```
##
## Error estimation of 'lm' using fixed training/validation set: 0.6905

tune(lm, li$call$formula, data = Advertising,
     tunecontrol = tune.control(sampling = "fix"))

##
## Error estimation of 'lm' using fixed training/validation set: 0.9951
```

5 Рисование

Вообще в R существует по крайней мери три “школы” рисования. Во-первых, это классический пакет `graphics`. Пользоваться я им не советую, во-первых, потому что в результате обычно получаются картинки посредственного качества, а во-вторых из-за его крайне примитивной идеалогии: график рассматрицается как холст, на котором можно что-то рисовать и подрисовывать, но нельзя ничего исправить.

Современный объектный подход к рисованию реализуют пакеты `lattice` и `ggplot2`. В них функции рисования возвращают некий объект, который можно модифицировать, хранить, передавать и, конечно же, отрисовывать на конкретном устрйстве.

Ниже я буду все графики делать в `lattice` из личных предпочтений. Некоторые находят `ggplot2` более эффективным и современным, но я привык к `lattice`.

Собственно, нам понадобится пакет `lattice` (он уже установлен, надо только подключить), а также будет полезным пакет `latticeExtra` (как видно из названия, он расширяет возможности `lattice`; его нужно поставить с CRAN).

Все функции рисования в `lattice` принимают следующие параметры:

1. `x` — формула; собственно, зависимость, которую мы хотим изобразить
2. `data` — данные, относительно которых будет вычисляться формула (просто датафрейм или именованный список, содержащий использованные в формуле переменные)
3. `groups` — параметр, позволяющий нарисовать несколько наложенных линий на одном графике
4. `panel` — панельная функция, как именно рисовать каждый отдельный график (панель)
5. `...` — параметры, передаваемые в пнельную функцию, а также всякие дополнительные параметры, вроде расположения и общего количества панелей.

На примере данных `iris`, посмотрим, какие бывают графики:

xyplot() — скаттерплот. Каждая строка датафрейма изображается отдельной точкой в координатах двух выбранных столбцов.

```
library(lattice)
xyplot(Sepal.Length ~ Petal.Length, data = iris)
```

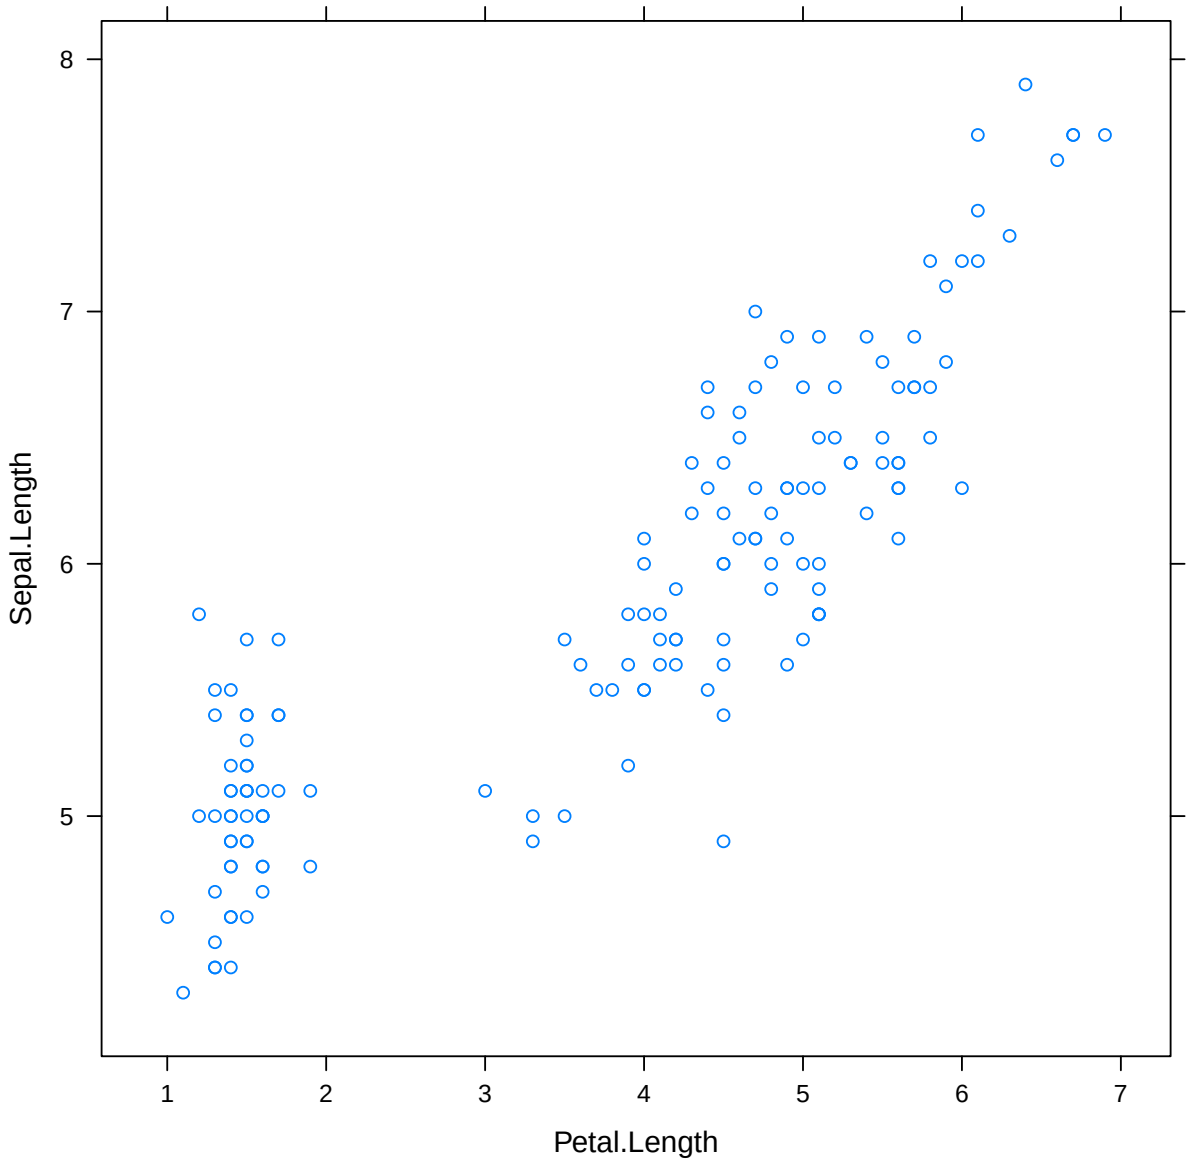

Не очень красиво и малоинформативно. Давайте нарисуем сорта на отдельных графиках:

```
xyplot(Sepal.Length ~ Petal.Length | Species, data = iris)
```

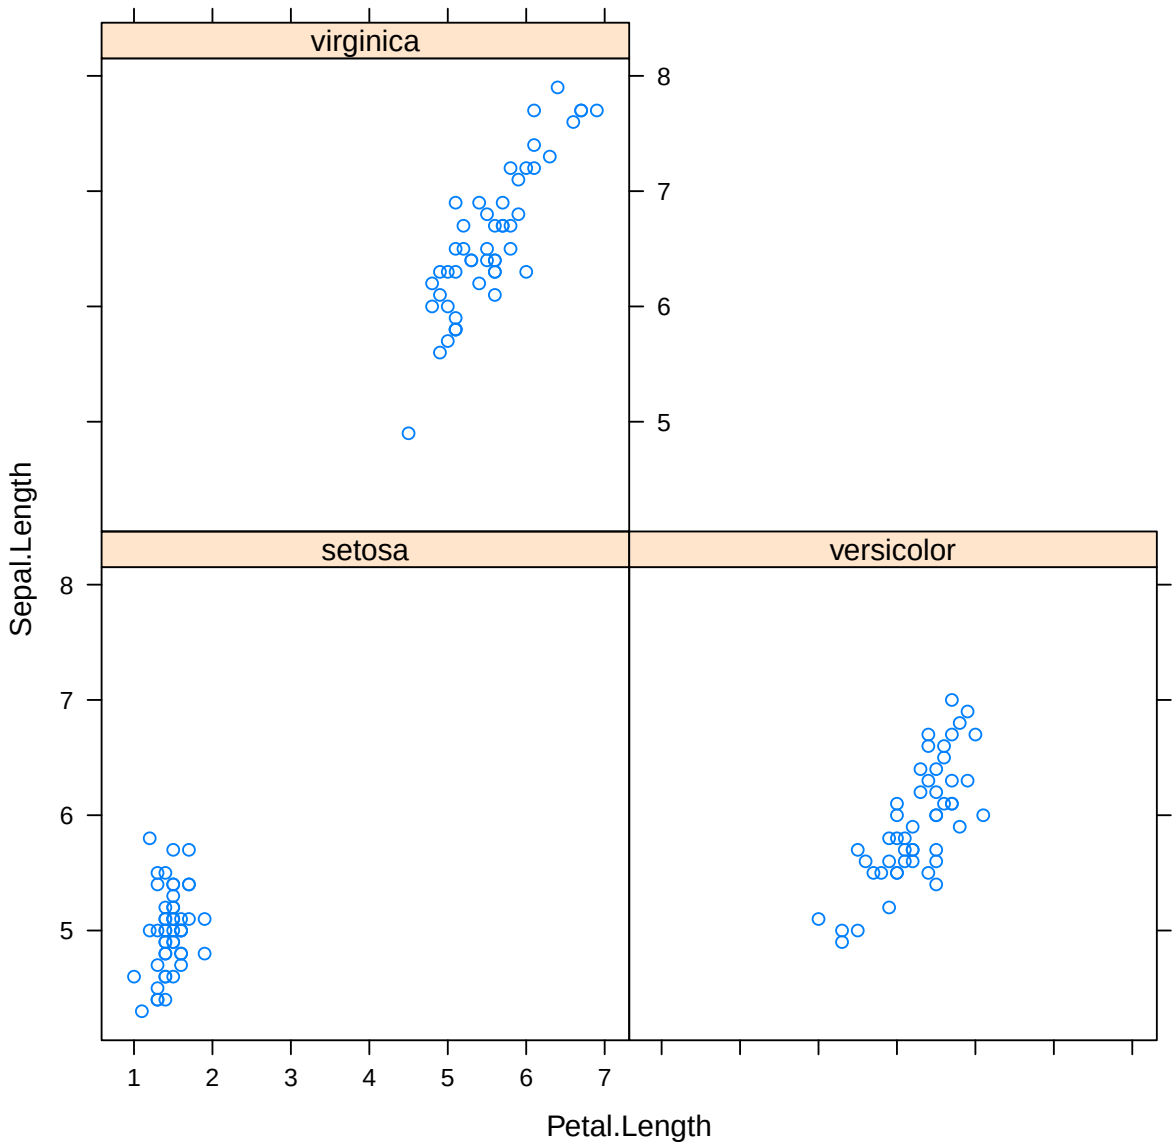

А может лучше все-таки на одном, но разными цветами?.. А еще я хочу сделать точки спрошным и добавить легенду:

```
xyplot(Sepal.Length ~ Petal.Length, groups = Species, data = iris, par.settings = s
19), auto.key = TRUE)
```

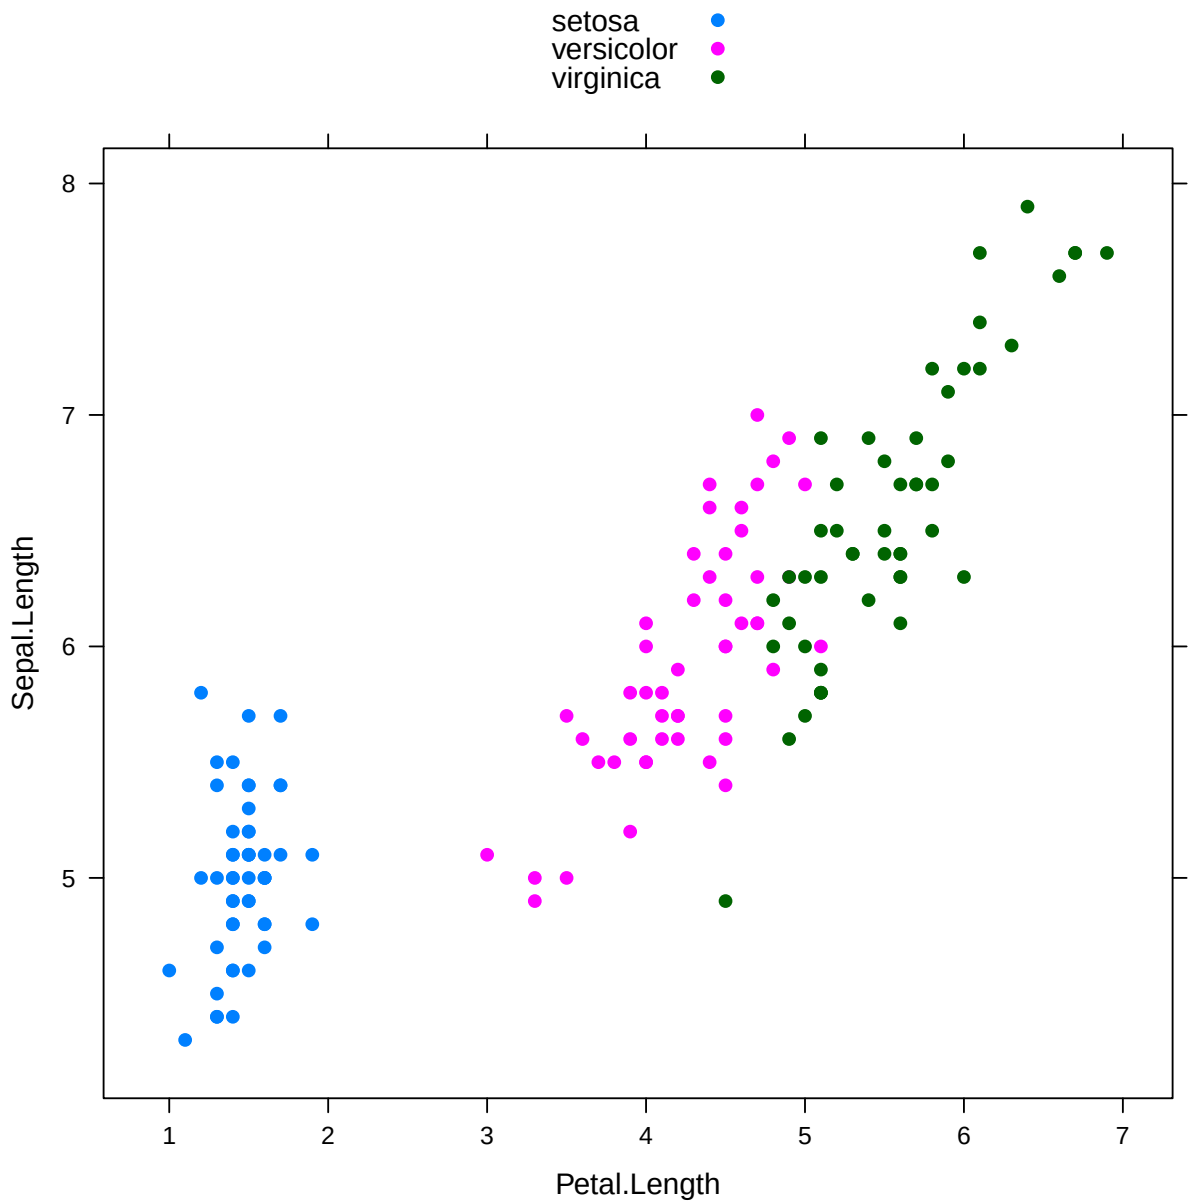


```
library(latticeExtra)
```

```
xyplot(Sepal.Length ~ Petal.Length,
       groups = Species,
       data = iris,
       par.settings = simpleTheme(pch = 19),
       auto.key = list(columns = 3, border = TRUE),
       panel = function(...) {panel.xyplot(...); panel.ellipse(...)},
       xlab = "Petal Length", ylab = "Sepal Length")
```

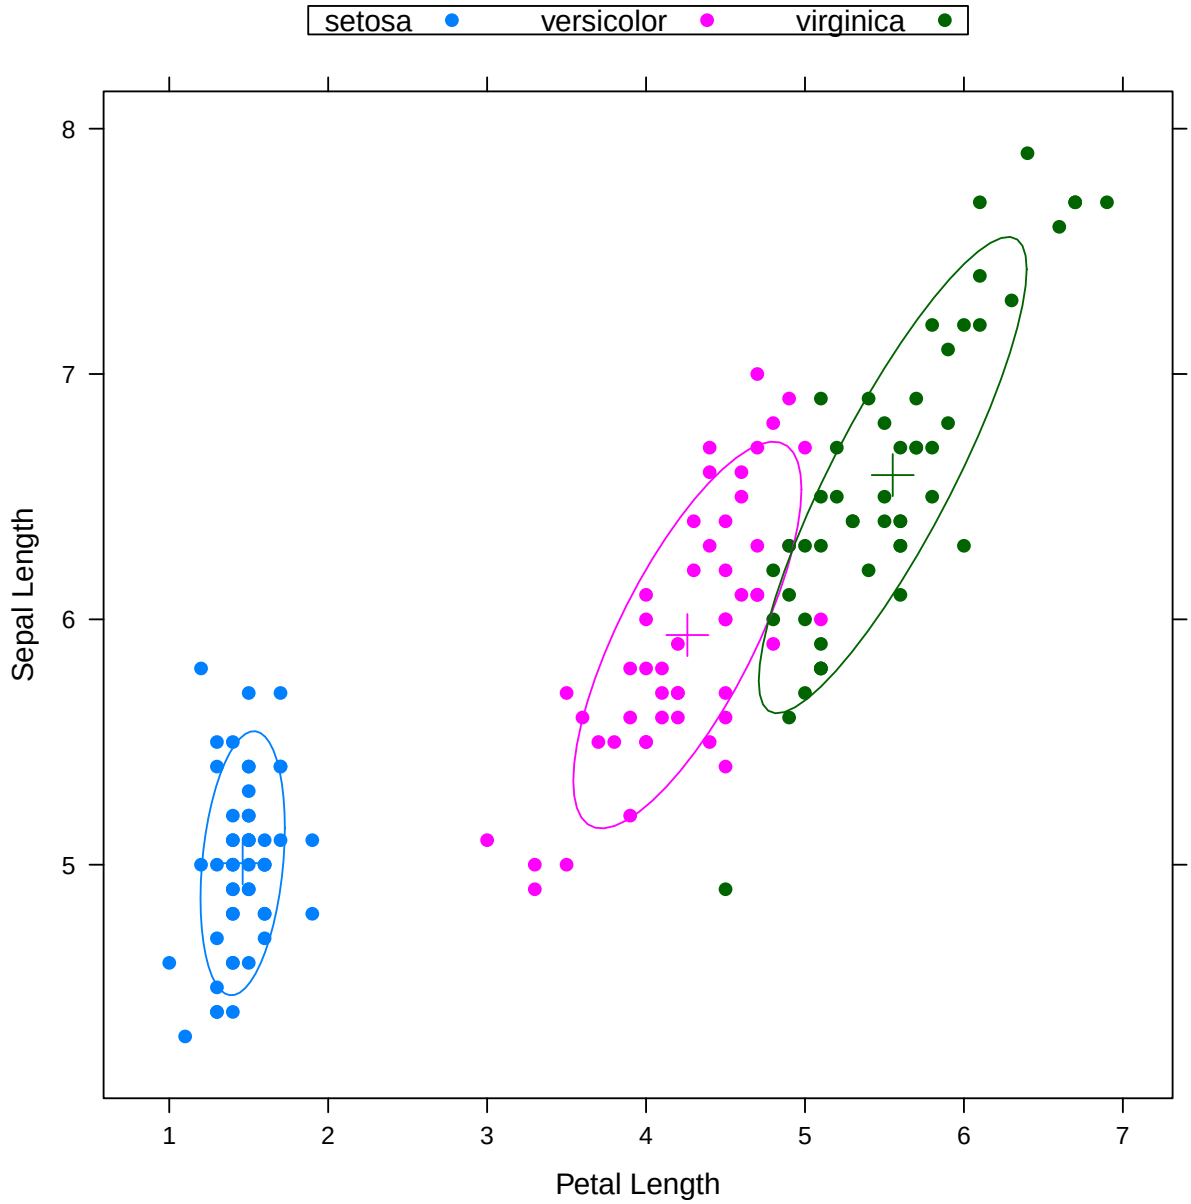

Напоследок приведу пример написания своей панельной функции для `xyplot()`:

```
read_chunk("panel.lmpolyline.R")
```

```
panel.lmpolyline <- function (x, y, groups = NULL, degree = 1,
                              col.line = par.line$col,
                              lty = par.line$lty,
                              lwd = par.line$lwd,
                              alpha = par.line$alpha,
                              ...,
                              identifier = "lmpolyline") {
  x <- as.numeric(x)
  y <- as.numeric(y)

  if (!is.null(groups)) {
```

```
    par.line <- trellis.par.get("superpose.line")
    panel.superpose(x = x, y = y,
                    groups = groups,
                    degree = degree,
                    col.line = col.line,
                    lty = lty,
                    lwd = lwd,
                    alpha = alpha,
                    panel.groups = sys.function(),
                    ...)
  } else {
    if (length(x) > degree) {
      l <- lm(y ~ poly(x, degree = degree))

      par.line <- trellis.par.get("plot.line")
      panel.curve(predict(l, list(x = x)), from = min(x), to = max(x),
                  col.line = col.line,
                  lty = lty,
                  lwd = lwd,
                  alpha = alpha,
                  ...,
                  identifier = identifier)
    }
  }
}

xyplot(Sepal.Length ~ Sepal.Width, data = iris, panel = panel.lmpolyline, degree =
```

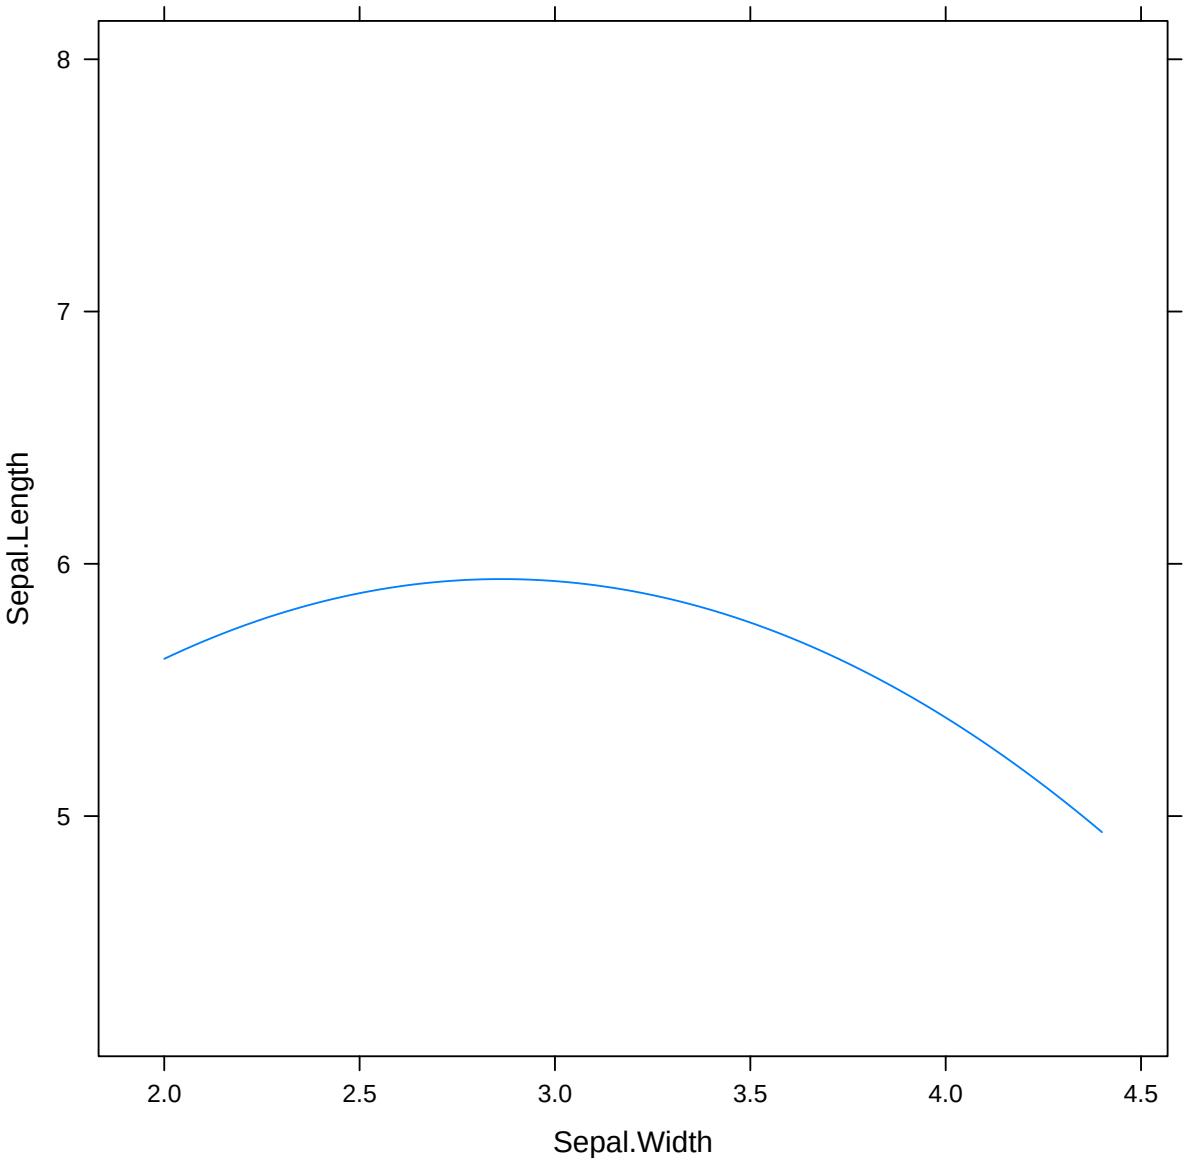


```
xyplot(Sepal.Length ~ Sepal.Width, groups = Species, data = iris, panel = panel.lmp
```

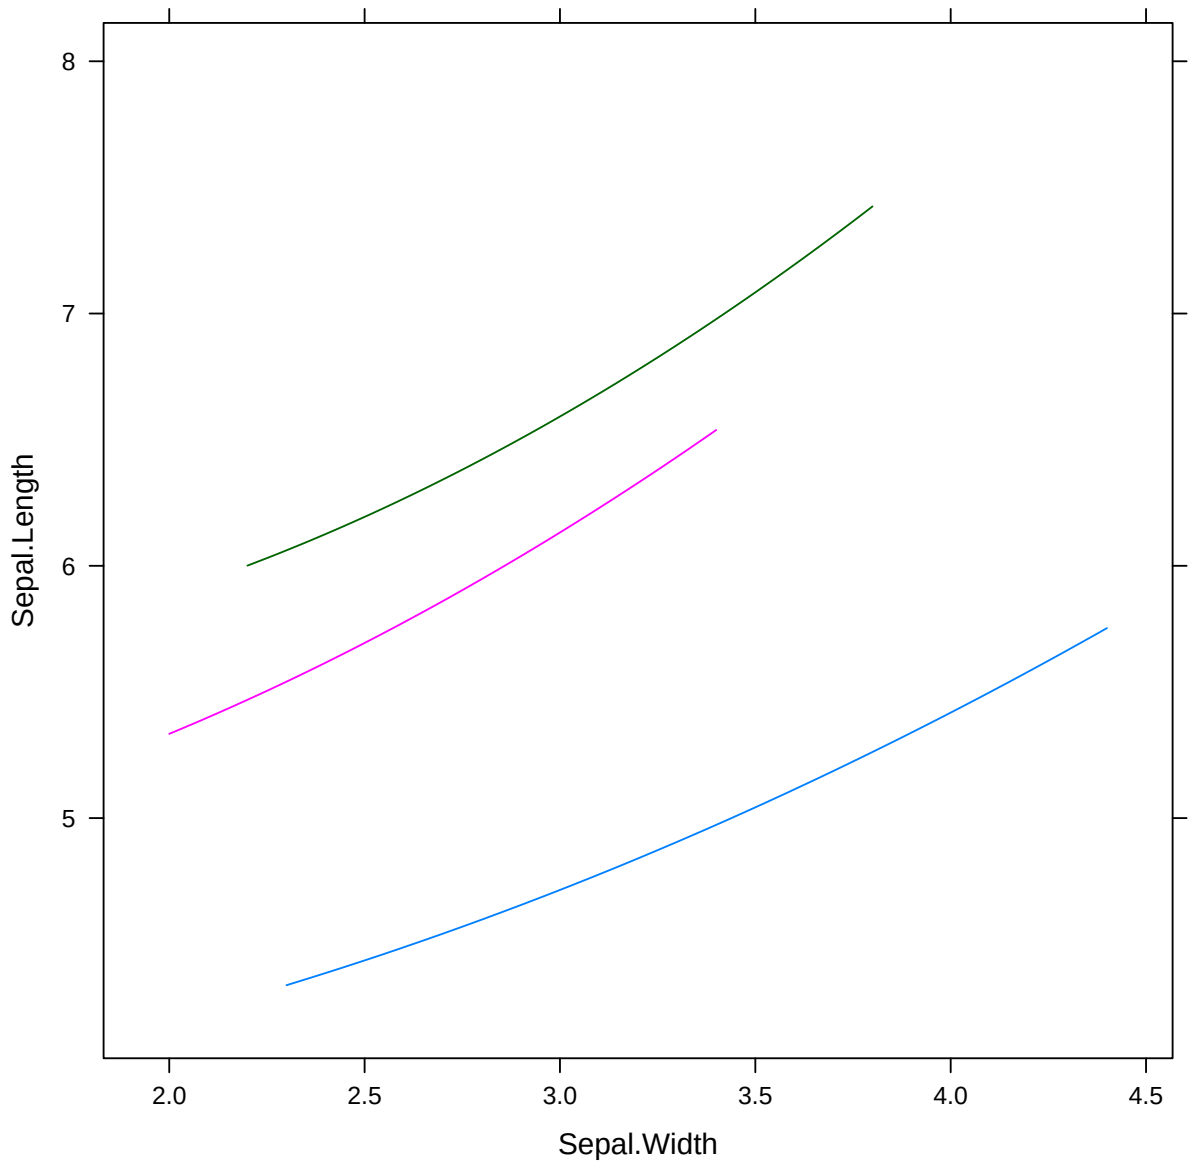


```
xyplot(Sepal.Length ~ Sepal.Width, groups = Species, data = iris) + layer_(panel.lm
```

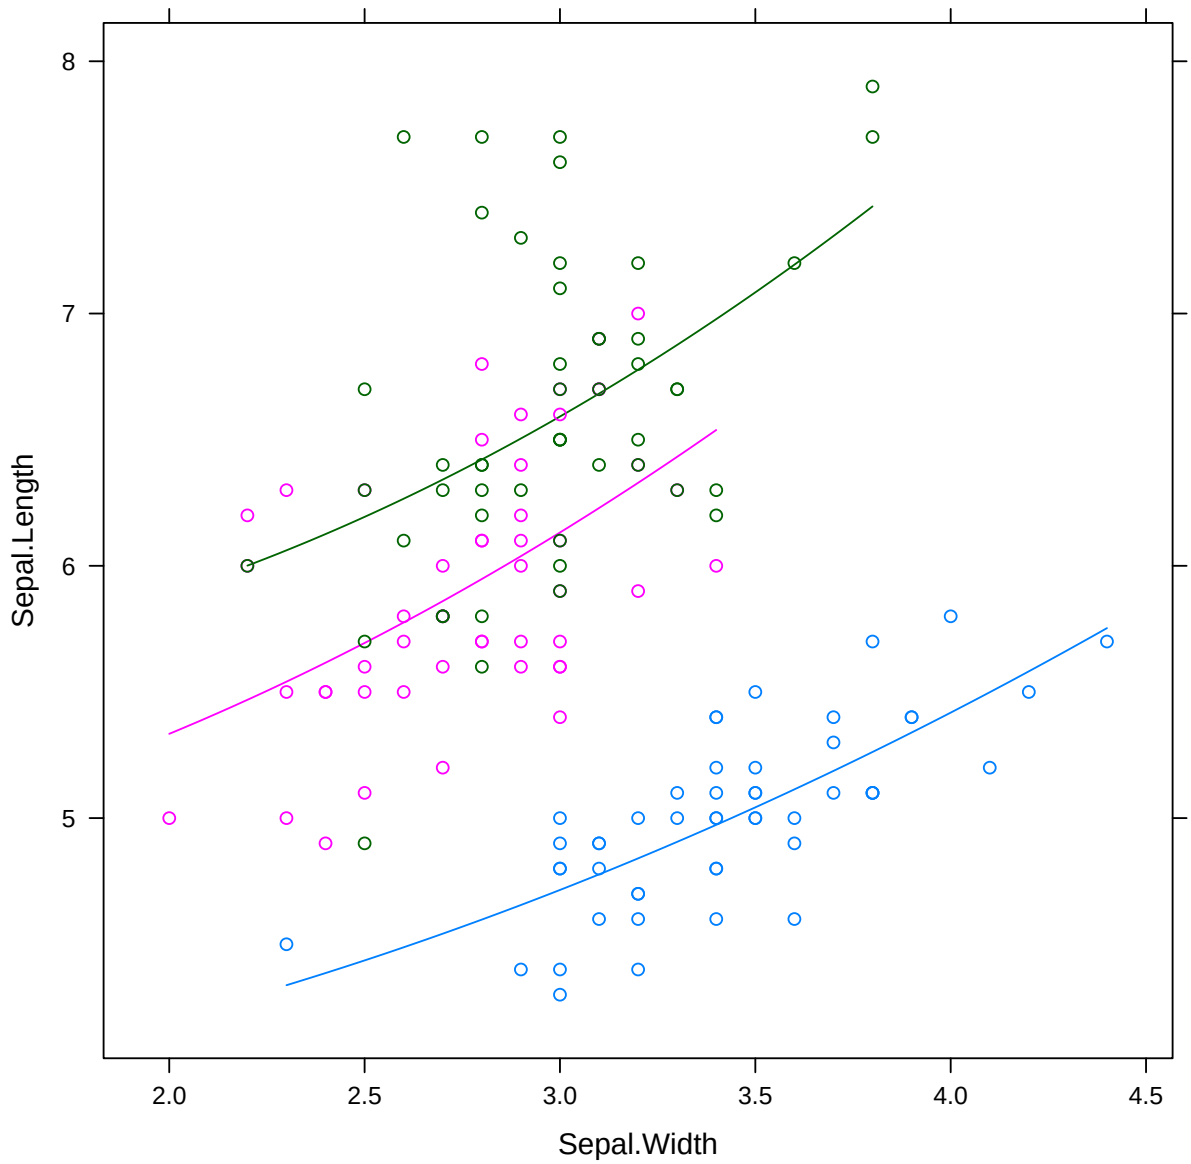


```
panel.kde2d <- function (x, y,
                         groups = NULL,
                         subscripts,
                         n = 100, cuts = 5,
                         col.line = par.line$col,
                         lty = par.line$lty,
                         lwd = par.line$lwd,
                         alpha = par.line$alpha,
                         ...,
                         identifier = "kde2d",
                         col) {
  require("MASS")

  x <- as.numeric(x)
  y <- as.numeric(y)
```

```r
  if (!is.null(groups)) {
    par.line <- trellis.par.get("superpose.line")
    panel.superpose(x = x, y = y,
                    groups = groups,
                    subscripts = subscripts,
                    n = n,
                    cuts = cuts,
                    panel.groups = sys.function(),
                    col.line = col.line,
                    lty = lty,
                    lwd = lwd,
                    alpha = alpha,
                    ...)
  } else {
    drange <- function(x) { r <- range(x); d <- diff(r); r + c(-d, d) }
    kde <- kde2d(x, y, n = n, lims = c(drange(x), drange(y)))
    data <- expand.grid(x = kde$x, y = kde$y)
    data$z <- as.vector(kde$z)

    plot.line <- trellis.par.get("plot.line")
    panel.contourplot(data$x, data$y, data$z,
                      at = pretty(data$z, n = cuts),
                      subscripts = seq_along(data$x),
                      contour = TRUE, region = FALSE,
                      col = col.line,
                      lty = lty,
                      lwd = lwd,
                      alpha = alpha,
                      ...,
                      identifier = identifier)
  }
}


xyplot(Sepal.Length ~ Sepal.Width, data = iris, groups = Species, panel = panel.kde
```

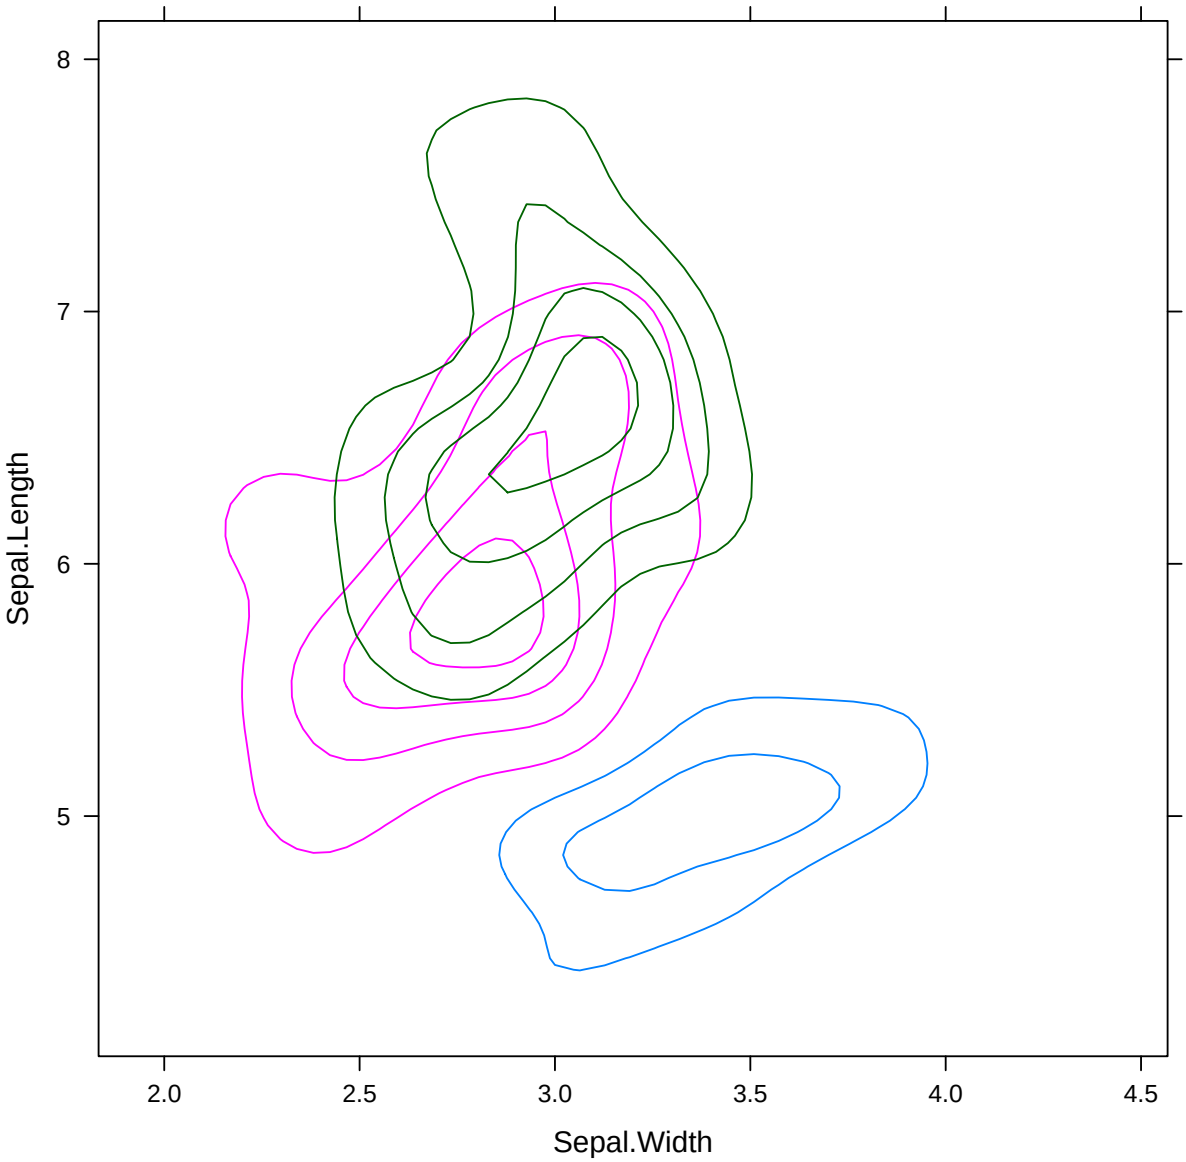


```
xyplot(Sepal.Length ~ Sepal.Width | Species, data = iris, groups = Species,
       par.settings = simpleTheme(pch = 19),
       auto.key = list(columns = 3, lines = TRUE),
       layout = c(3, 1)) + layer_(panel.kde2d(..., cuts = 10))
```

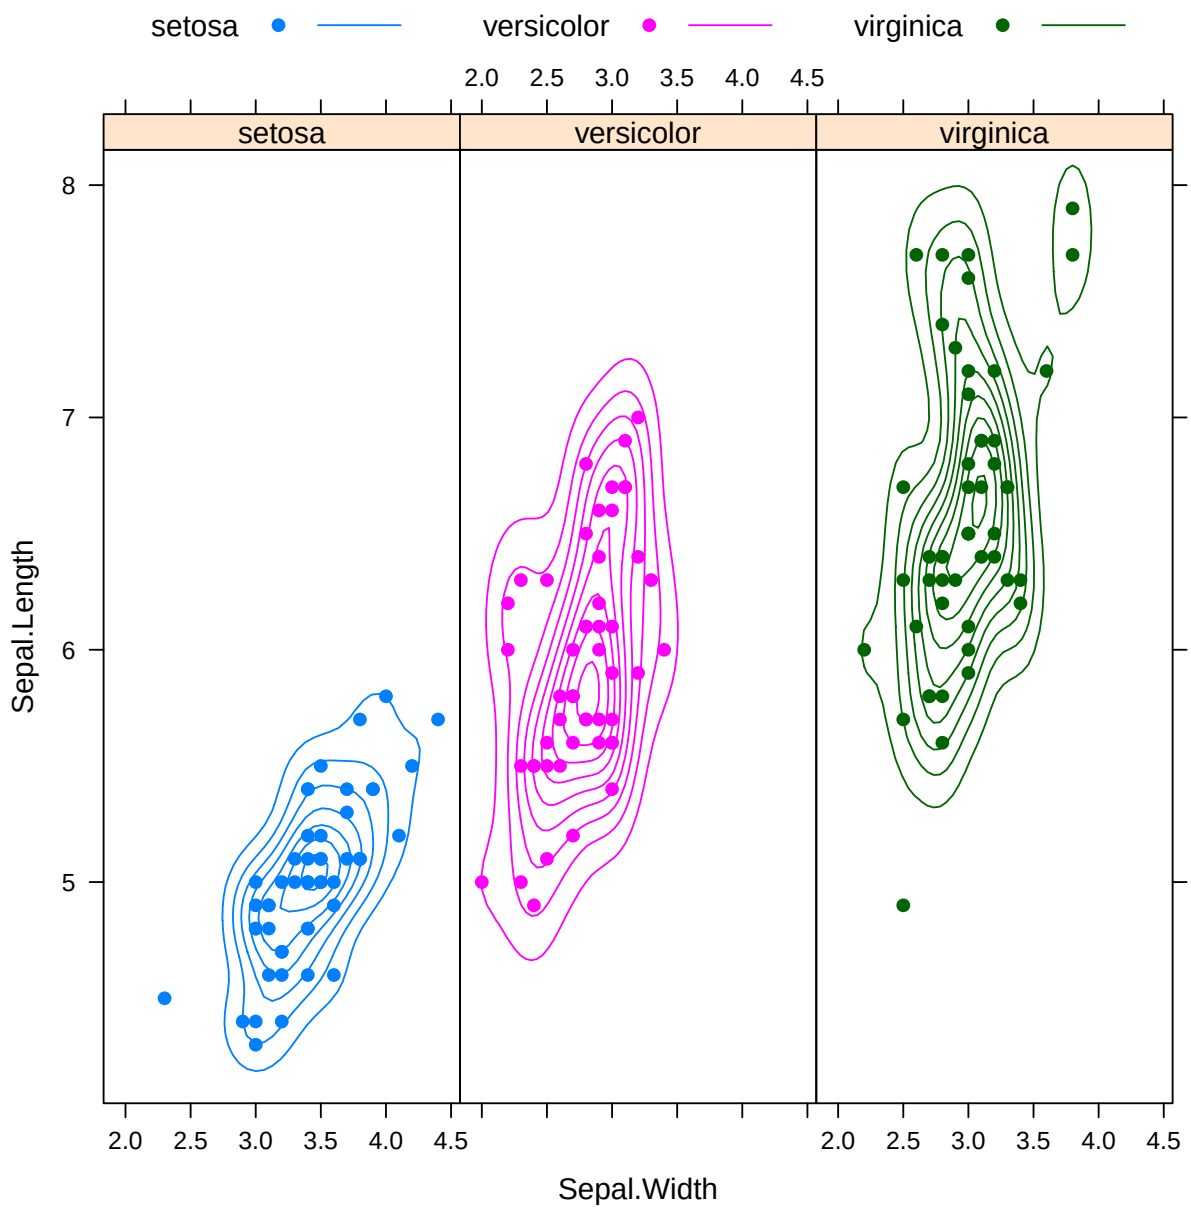


```
xyplot(Sepal.Length ~ Sepal.Width | Species, data = iris, groups = Species,
       par.settings = simpleTheme(pch = 19),
       layout = c(3, 1)) + layer_(panel.kde2d(..., cuts = 10))
```

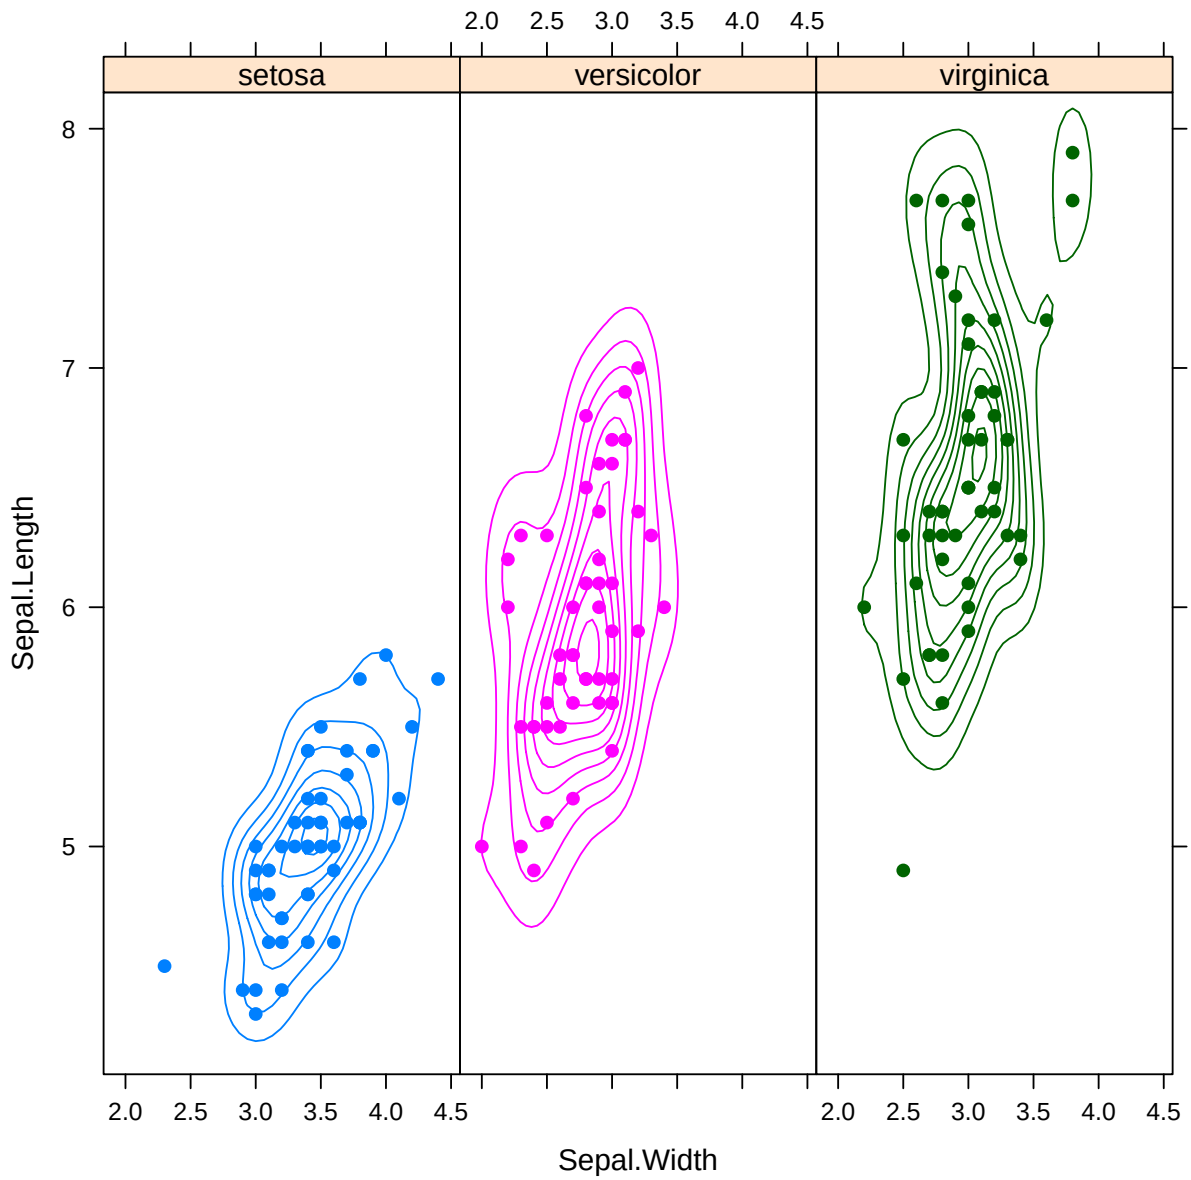


```
xyplot(Sepal.Length ~ Sepal.Width | Species, data = iris, groups = Species,
       par.settings = simpleTheme(pch = 19, cex = 0.5, lwd = 1, lty = "dashed"),
       auto.key = list(columns = 3, lines = TRUE),
       layout = c(3, 1)) + layer_(panel.kde2d(..., cuts = 10))
```

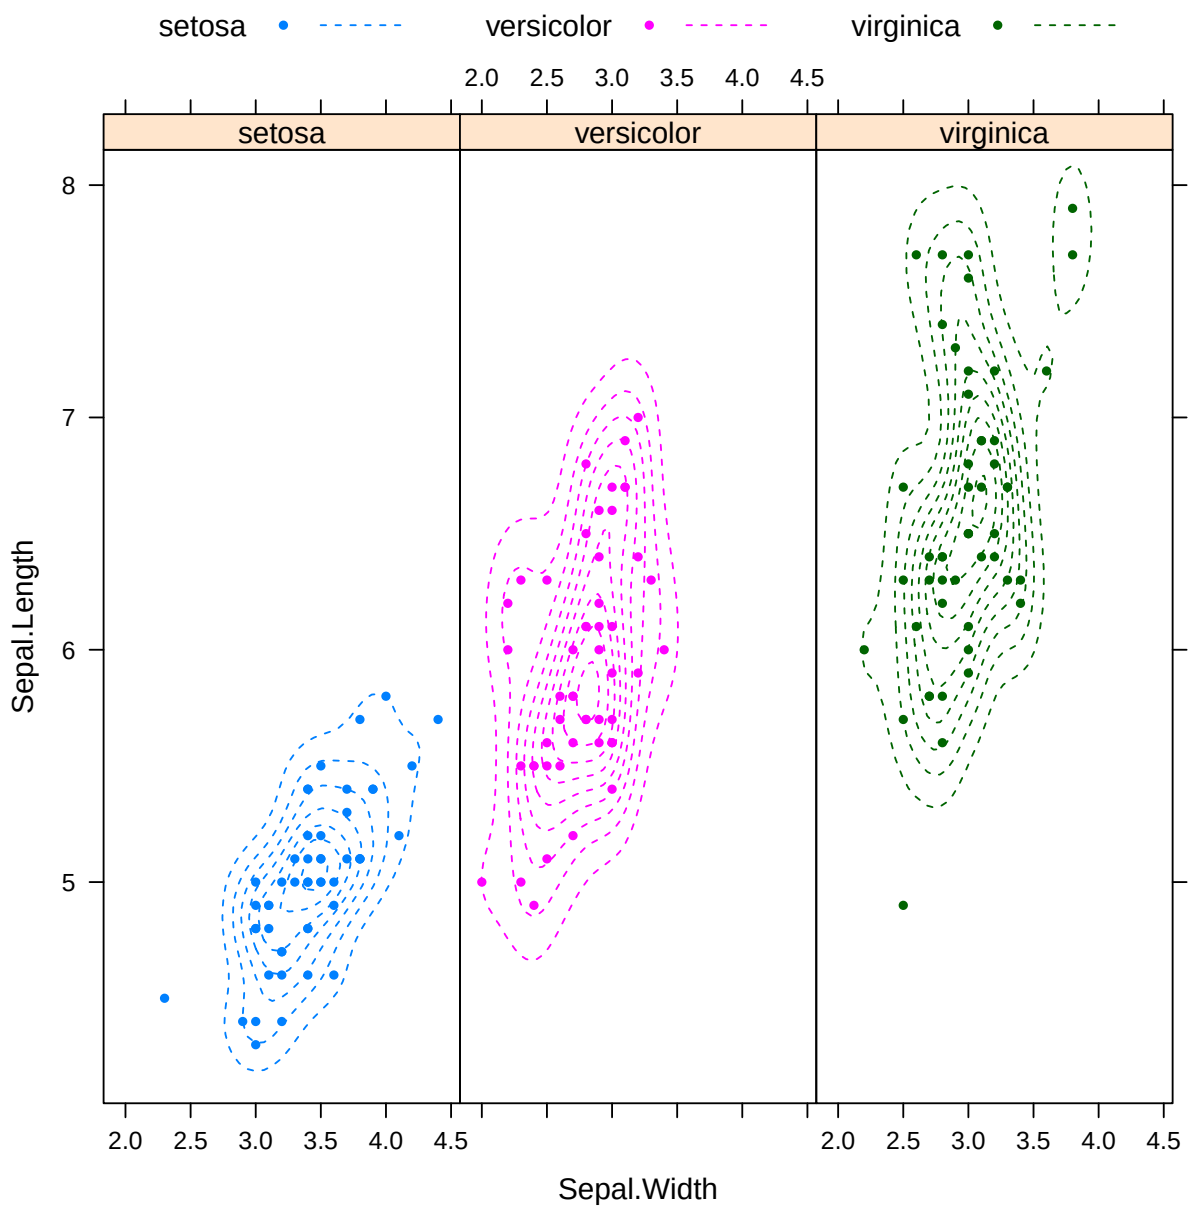

bwplot violinplot densityplot marginal.plot
countourplot
Пример панельной функции для полиномиальной регрессии