R, Quick start to data analysis

Alex Shlemov Anton Korobeynikov

14 октября 2014 г.

Содержание

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).

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

```
> 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”:

```
> 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: 0x2d912c8>
## <environment: namespace:base>
```

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

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

```
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:

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

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

l[-2]

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

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

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

```
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 NULL 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 NULL в список, то это делается так:

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

4 Материалы с занятия 3 октября

4.1 Toothgrowth

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

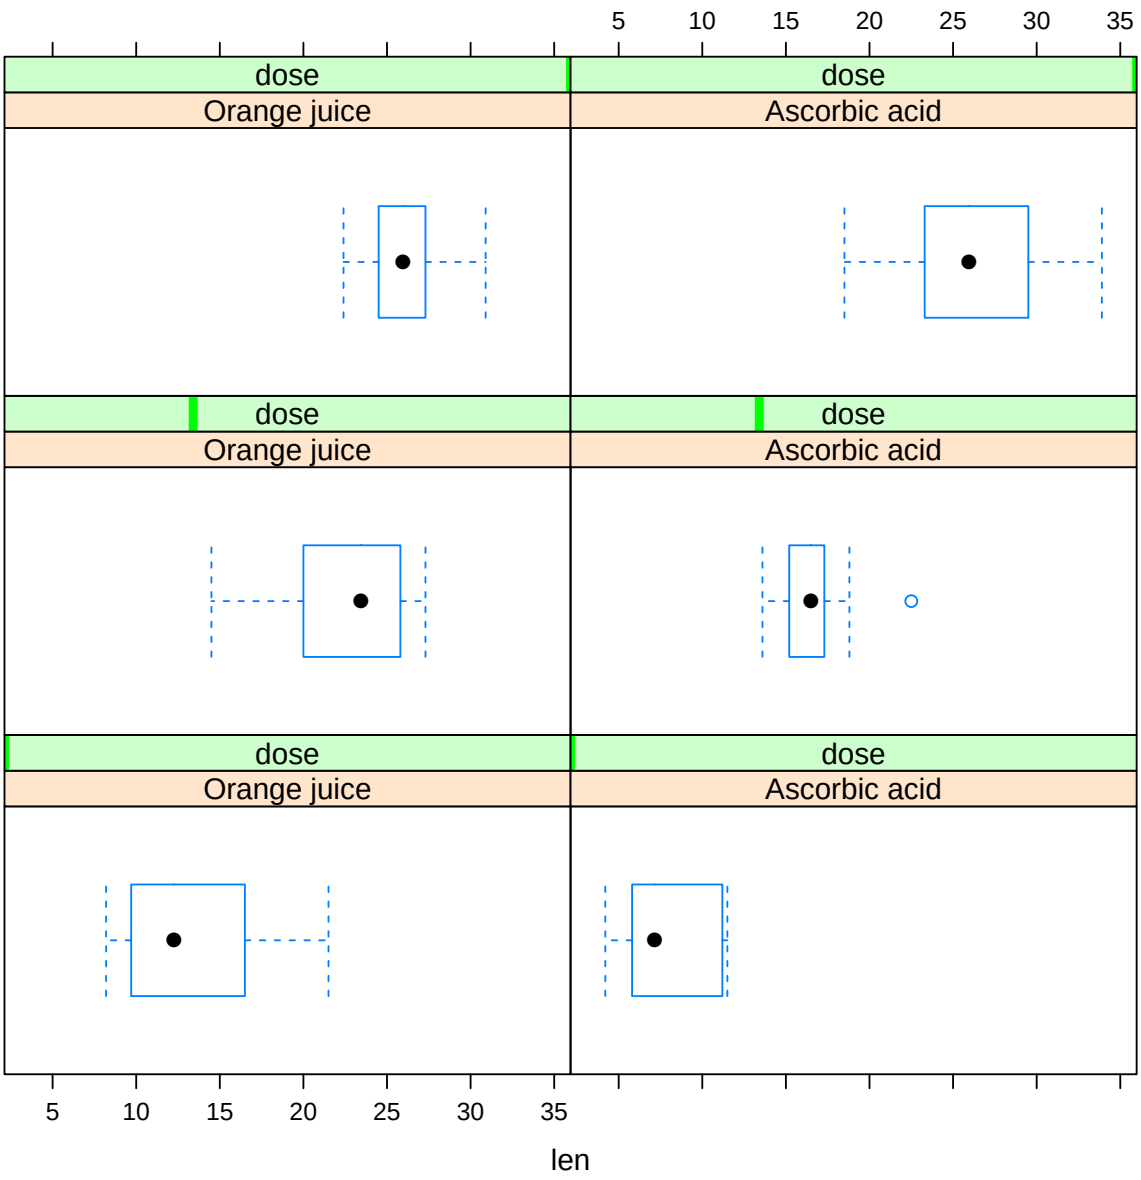


```
bwplot(~len | dose * supp, data = tooth)
```

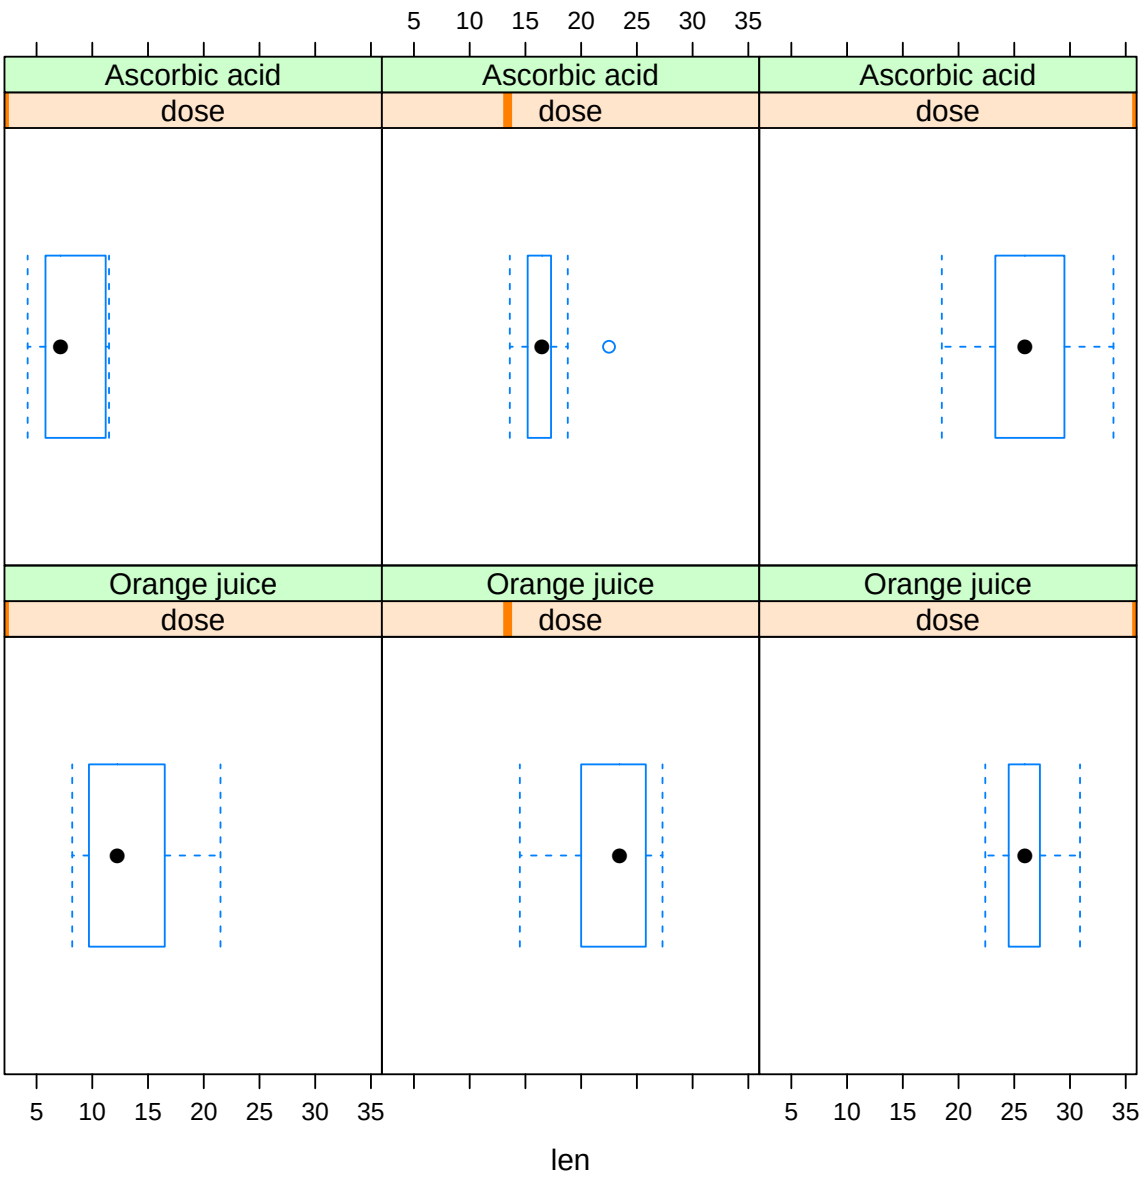


```
contrasts(tooth$supp)

##                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)   7.4225     1.1599   6.399 3.17e-08 ***
## supp1         1.8500     0.5468   3.383   0.0013 **
## dose          9.7636     0.8768  11.135 6.31e-16 ***
## ---
## Signif. codes:
## 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 4.236 on 57 degrees of freedom
## Multiple R-squared:  0.7038,Adjusted R-squared:  0.6934
## F-statistic: 67.72 on 2 and 57 DF,  p-value: 8.716e-16

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

##
## Call:
## lm(formula = len ~ supp * dose, data = tooth)
##
## Residuals:
##     Min      1Q  Median      3Q     Max
## -8.2264 -2.8462  0.0504  2.2893  7.9386
##
## Coefficients:
##             Estimate Std. Error t value Pr(>|t|)
## (Intercept)   7.4225     1.1182   6.638 1.37e-08 ***
## supp1         4.1275     1.1182   3.691 0.000507 ***
## dose          9.7636     0.8453  11.551  < 2e-16 ***
## supp1:dose   -1.9521     0.8453  -2.309 0.024631 *
## ---
## Signif. codes:
## 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 4.083 on 56 degrees of freedom
## Multiple R-squared:  0.7296,Adjusted R-squared:  0.7151
## F-statistic: 50.36 on 3 and 56 DF,  p-value: 6.521e-16

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

```
##                  .L         .Q
## [1,] -7.071068e-01  0.4082483
## [2,] -7.850462e-17 -0.8164966
## [3,]  7.071068e-01  0.4082483
```

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

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

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

```
##
## Call:
## lm(formula = len ~ supp * dose, data = tooth)
##
## Residuals:
##    Min     1Q Median     3Q    Max
##  -8.20  -2.72  -0.27   2.65   8.27
##
## Coefficients:
##             Estimate Std. Error t value Pr(>|t|)
## (Intercept)  18.8133     0.4688  40.130  < 2e-16 ***
## supp1         1.8500     0.4688   3.946 0.000231 ***
## dose1         4.5650     0.5742   7.951 1.19e-10 ***
## dose2         3.6433     0.3315  10.990 2.17e-15 ***
## supp1:dose1   0.1700     0.5742   0.296 0.768308
## supp1:dose2  -0.9450     0.3315  -2.851 0.006166 **
## ---
## Signif. codes:
## 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 3.631 on 54 degrees of freedom
## Multiple R-squared:  0.7937,Adjusted R-squared:  0.7746
## F-statistic: 41.56 on 5 and 54 DF,  p-value: < 2.2e-16
```

```r
stepAIC(l)
```

```
## Start:  AIC=160.43
## len ~ supp * dose
##
##             Df Sum of Sq    RSS    AIC
## <none>                   712.11 160.43
## - supp:dose  2    108.32 820.43 164.93
##
```

```
## 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      7 332.7056
## l.lin  5 337.2013

BIC(l, l.lin)

##       df     BIC
## l      7 347.366
## l.lin  5 347.673

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     54 712.11
## 2     56 820.43 -2   -108.32 4.107 0.02186 *
## ---
## 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))
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
```

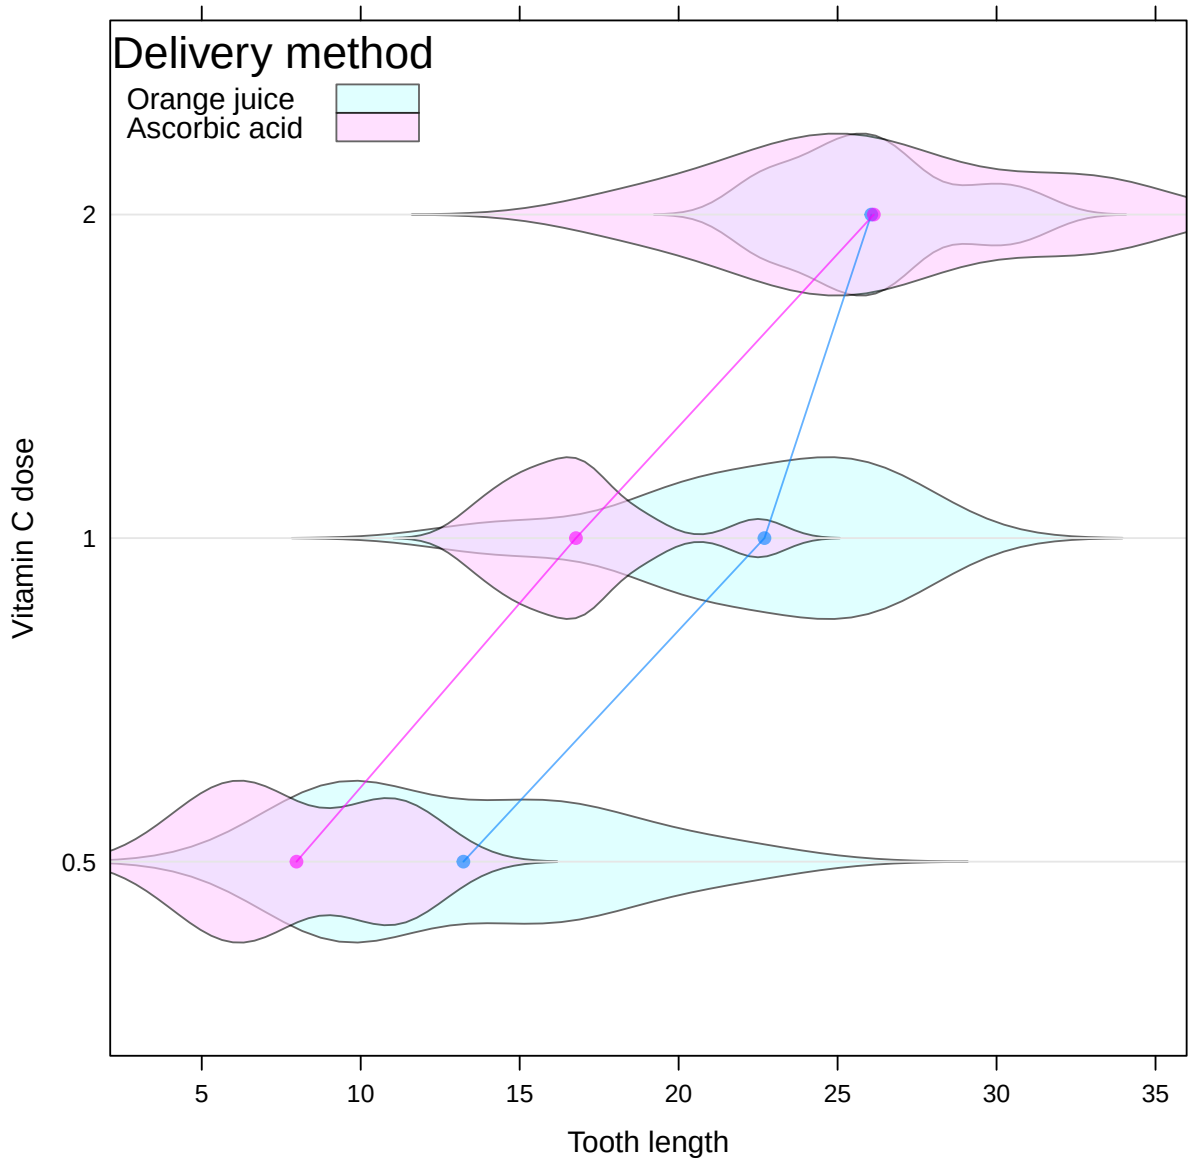

4.2 Графики residuals-vs-fitted

```
library(lattice)
library(latticeExtra)
library(MASS)
panel <- function(...) {
    panel.xyplot(...)
```

```r
    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))
```

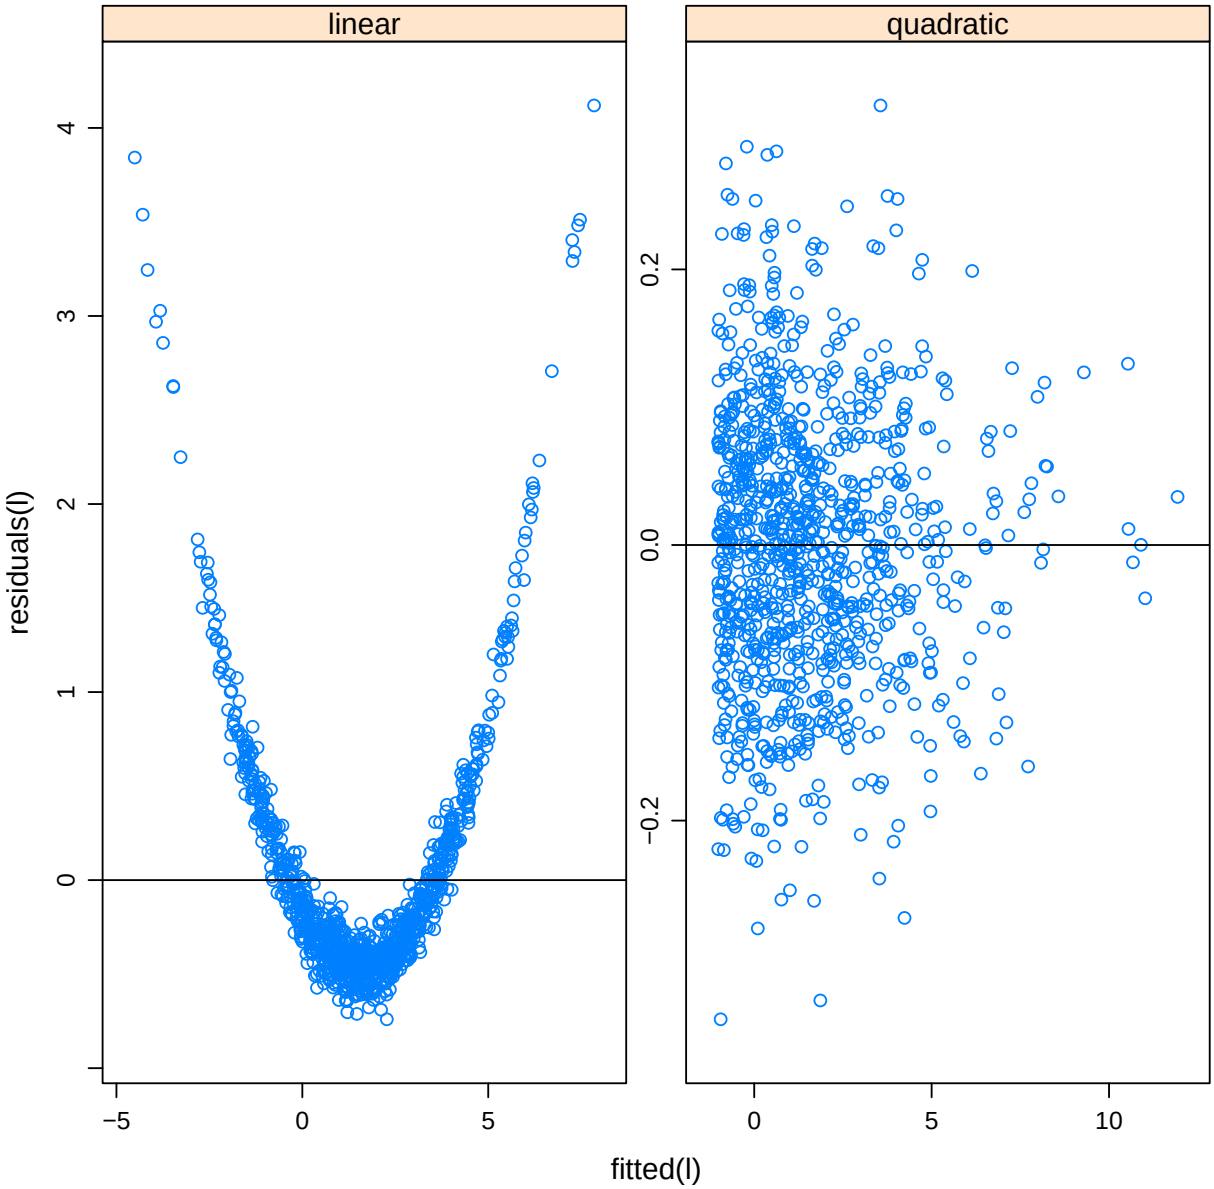


```
y <- exp(beta0 + beta1 * x + rnorm(N, sd = 0.5))
df <- data.frame(y = y, x = x)
l <- lm(y ~ x, data = df)
l2 <- lm(log(y) ~ x, data = df)
p1 <- xyplot(residuals(l) ~ fitted(l), panel = panel)
p2 <- xyplot(residuals(l2) ~ fitted(l2),
    panel = panel)
plot(c(original = p1, logarithm = p2))
```

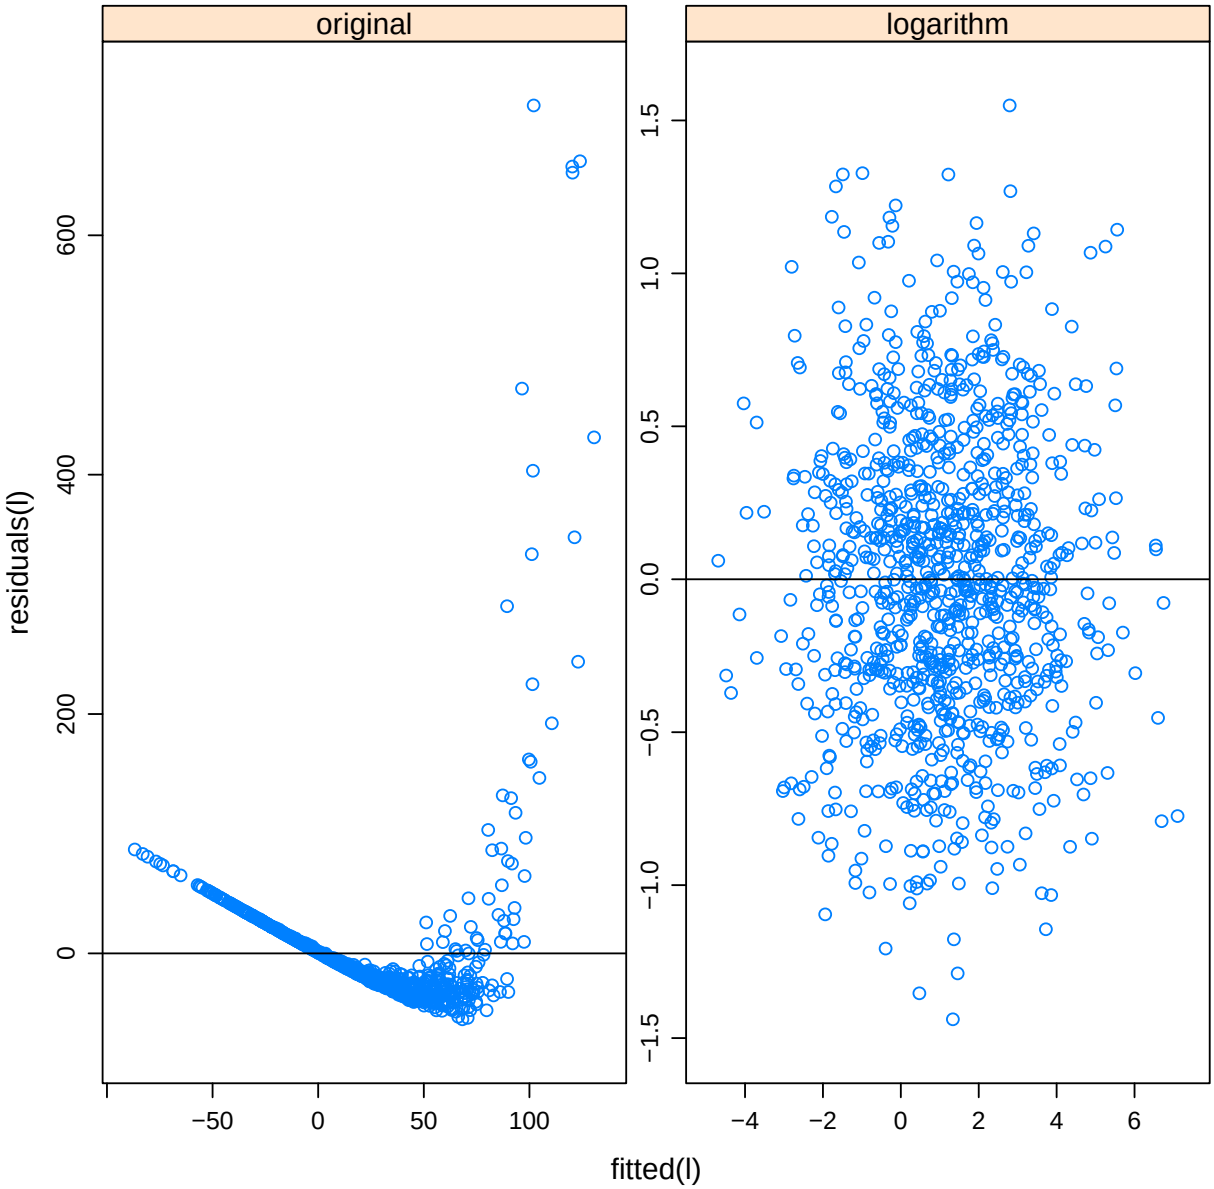


```
Auto <- read.table("Auto.data", header = TRUE,
    na.strings = "?")
Auto <- na.omit(Auto)
xyplot(mpg ~ horsepower, data = Auto)
```

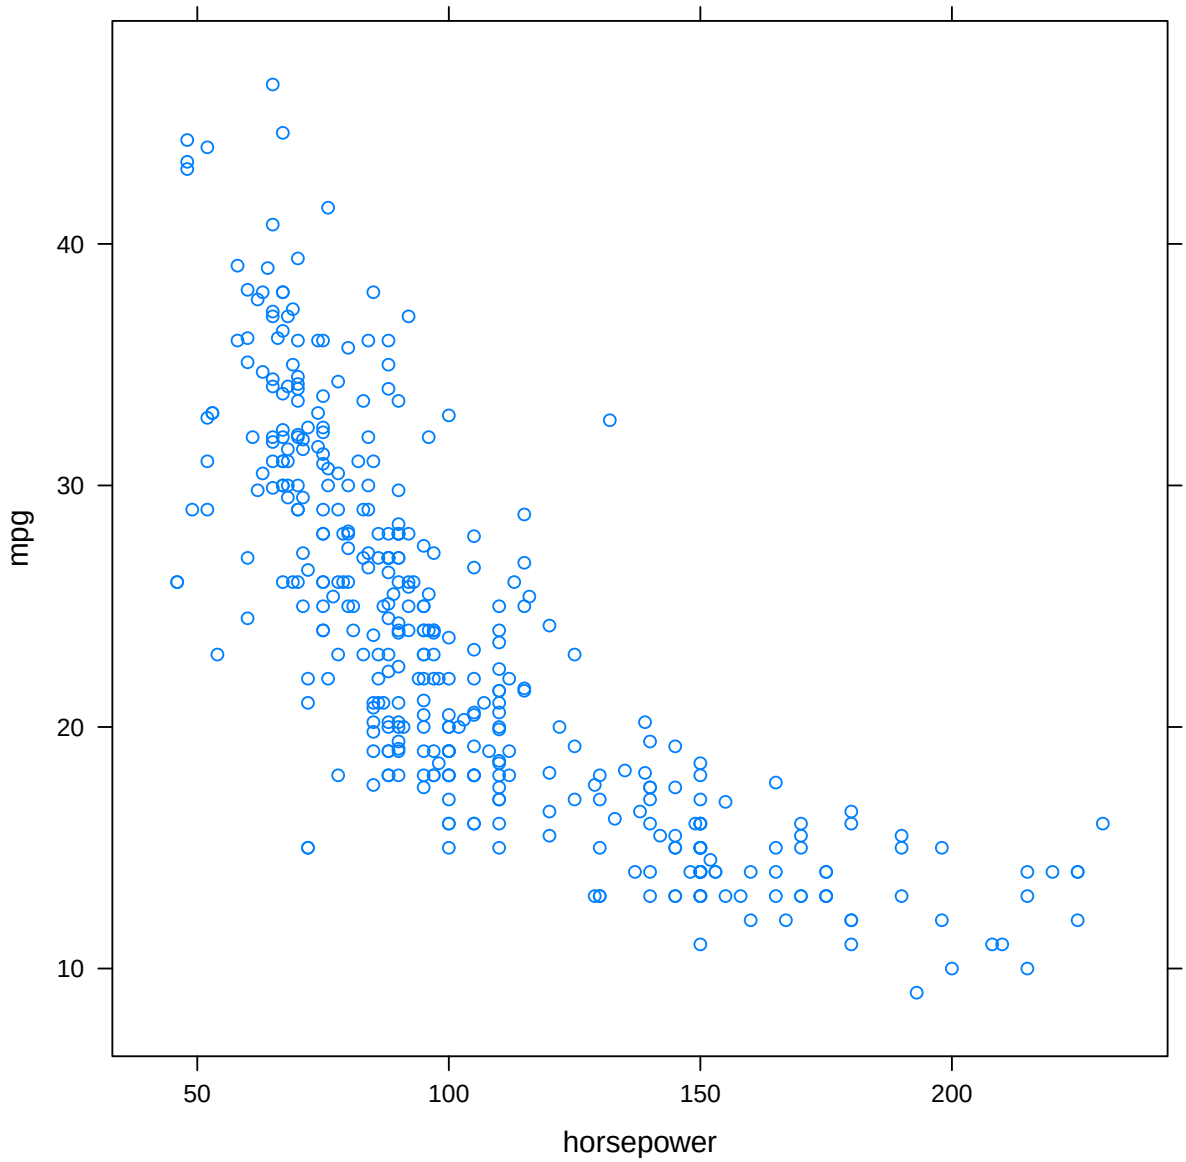


```
xyplot(mpg ~ log(horsepower), data = Auto)
```

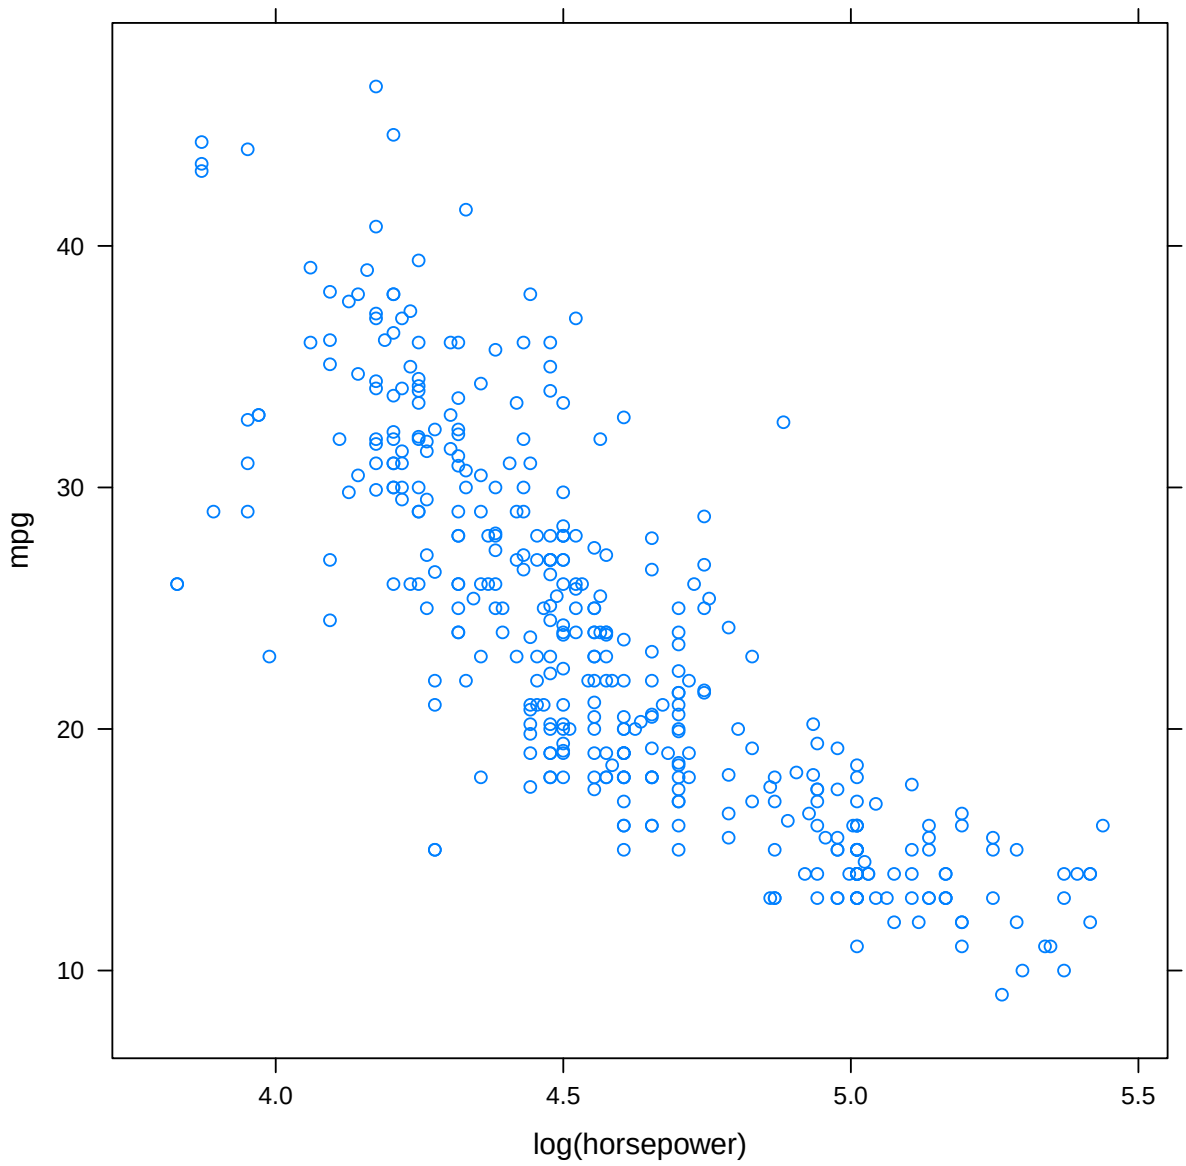


```
l1 <- lm(mpg ~ horsepower, data = Auto)
l2 <- lm(mpg ~ poly(horsepower, degree = 2),
    data = Auto)
llog <- lm(mpg ~ log(horsepower), data = Auto)
l5 <- lm(mpg ~ poly(horsepower, degree = 5),
    data = Auto)
l6 <- lm(mpg ~ poly(horsepower, degree = 6),
    data = Auto)
summary(l1)

##
## Call:
## lm(formula = mpg ~ horsepower, data = Auto)
##
## Residuals:
```

```
##      Min       1Q   Median       3Q      Max
## -13.5710  -3.2592  -0.3435   2.7630  16.9240
##
## Coefficients:
##              Estimate Std. Error t value Pr(>|t|)
## (Intercept) 39.935861   0.717499   55.66   <2e-16 ***
## horsepower  -0.157845   0.006446  -24.49   <2e-16 ***
## ---
## Signif. codes:
## 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 4.906 on 390 degrees of freedom
## Multiple R-squared:  0.6059,Adjusted R-squared:  0.6049
## F-statistic: 599.7 on 1 and 390 DF,  p-value: < 2.2e-16
```

```r
summary(llog)
```

```
##
## Call:
## lm(formula = mpg ~ log(horsepower), data = Auto)
##
## Residuals:
##      Min       1Q   Median       3Q      Max
## -14.2299  -2.7818  -0.2322   2.6661  15.4695
##
## Coefficients:
##                 Estimate Std. Error t value Pr(>|t|)
## (Intercept)     108.6997     3.0496   35.64   <2e-16 ***
## log(horsepower) -18.5822     0.6629  -28.03   <2e-16 ***
## ---
## Signif. codes:
## 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 4.501 on 390 degrees of freedom
## Multiple R-squared:  0.6683,Adjusted R-squared:  0.6675
## F-statistic: 785.9 on 1 and 390 DF,  p-value: < 2.2e-16
```

```r
summary(l5)
```

```
##
## Call:
## lm(formula = mpg ~ poly(horsepower, degree = 5), data = Auto)
##
## Residuals:
##      Min       1Q   Median       3Q      Max
## -15.4326  -2.5285  -0.2925   2.1750  15.9730
##
## Coefficients:
##                                Estimate Std. Error t value
```

```
## (Intercept)                      23.4459     0.2185 107.308
## poly(horsepower, degree = 5)1 -120.1377     4.3259 -27.772
## poly(horsepower, degree = 5)2   44.0895     4.3259  10.192
## poly(horsepower, degree = 5)3   -3.9488     4.3259  -0.913
## poly(horsepower, degree = 5)4   -5.1878     4.3259  -1.199
## poly(horsepower, degree = 5)5   13.2722     4.3259   3.068
##                                 Pr(>|t|)
## (Intercept)                      < 2e-16 ***
## poly(horsepower, degree = 5)1  < 2e-16 ***
## poly(horsepower, degree = 5)2  < 2e-16 ***
## poly(horsepower, degree = 5)3  0.36190
## poly(horsepower, degree = 5)4  0.23117
## poly(horsepower, degree = 5)5  0.00231 **
## ---
## Signif. codes:
## 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 4.326 on 386 degrees of freedom
## Multiple R-squared:  0.6967,Adjusted R-squared:  0.6928
## F-statistic: 177.4 on 5 and 386 DF,  p-value: < 2.2e-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)                      23.4459     0.2177 107.715
## poly(horsepower, degree = 6)1 -120.1377     4.3096 -27.877
## poly(horsepower, degree = 6)2   44.0895     4.3096  10.231
## poly(horsepower, degree = 6)3   -3.9488     4.3096  -0.916
## poly(horsepower, degree = 6)4   -5.1878     4.3096  -1.204
## poly(horsepower, degree = 6)5   13.2722     4.3096   3.080
## poly(horsepower, degree = 6)6   -8.5462     4.3096  -1.983
##                                 Pr(>|t|)
## (Intercept)                      < 2e-16 ***
## poly(horsepower, degree = 6)1  < 2e-16 ***
## poly(horsepower, degree = 6)2  < 2e-16 ***
## poly(horsepower, degree = 6)3  0.36008
## poly(horsepower, degree = 6)4  0.22941
## poly(horsepower, degree = 6)5  0.00222 **
## poly(horsepower, degree = 6)6  0.04807 *
```

```
## ---
## 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:  0.6998,Adjusted R-squared:  0.6951
## F-statistic: 149.6 on 6 and 385 DF,  p-value: < 2.2e-16
```

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

```
##      df      AIC
## l1    3 2363.324
## l2    4 2274.354
## llog  3 2295.760
## l5    7 2268.663
## l6    8 2266.680
```

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

```
##      df      BIC
## l1    3 2375.237
## l2    4 2290.239
## llog  3 2307.674
## l5    7 2296.462
## l6    8 2298.450
```

```
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 9385.9
## 2    389 7442.0  1    1943.9 101.61 < 2.2e-16 ***
## ---
## Signif. codes:
## 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

```
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 9385.9
## 2    386 7223.4  4    2162.5 28.89 < 2.2e-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 9385.9
## 2    385 7150.3  5    2235.6 24.074 < 2.2e-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 7223.4
## 2    385 7150.3  1    73.038 3.9326 0.04807 *
## ---
## Signif. codes:
## 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
```

4.3 Линейная регрессия (Университеты)

```r
library(MASS)
library(lattice)
library(latticeExtra)
library(latticist)
df <- read.csv2(file = "I.csv")
# 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 -
```

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

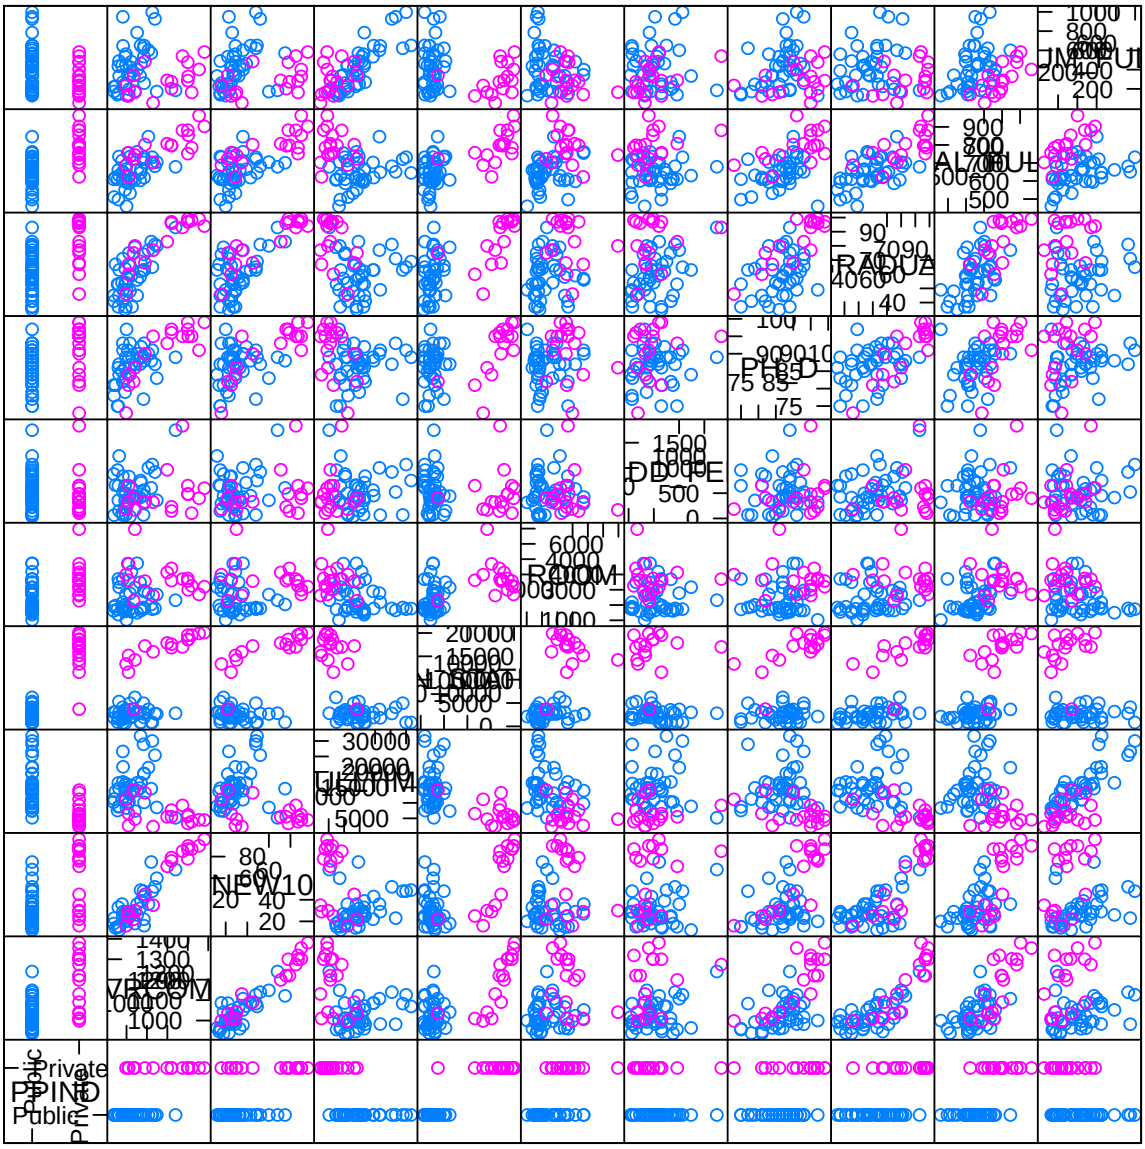

Scatter Plot Matrix

```
# 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))
```

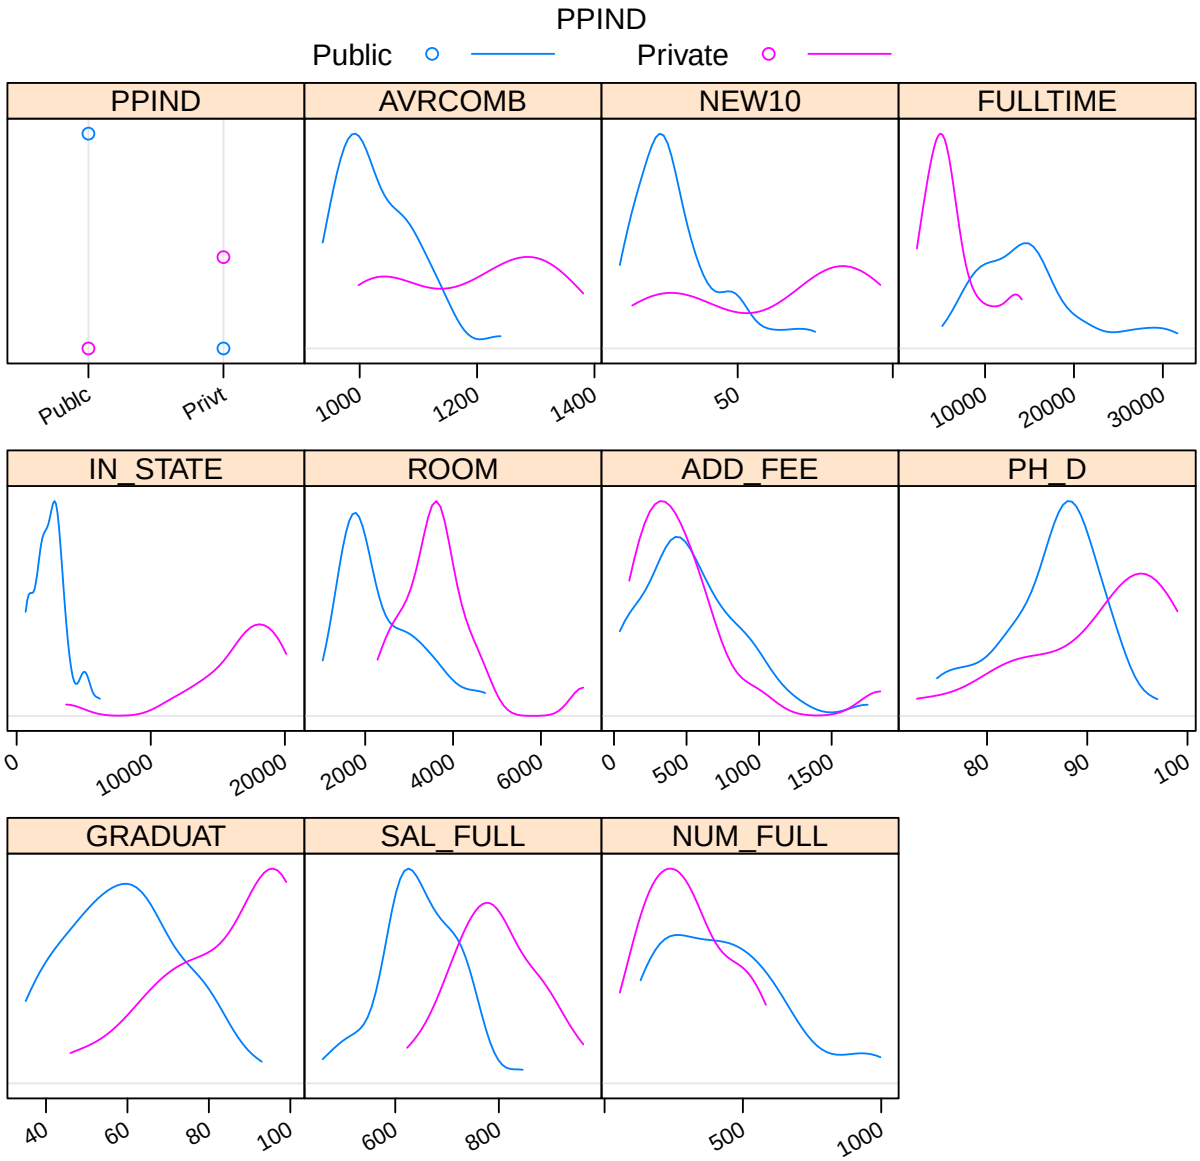


```r
df.pub <- subset(df, PPIND == "Public")
# Теперь посмотрим на нормальность,
# может, что-то стоит
# прологарифмировать?...
# latticist(df.pub) Подозрение падает на
# денежные признаки. Они часто
# логнормальны.
marginal.plot(subset(df.pub, select = c(ADD_FEE,
    ROOM, IN_STATE, SAL_FULL)))
```

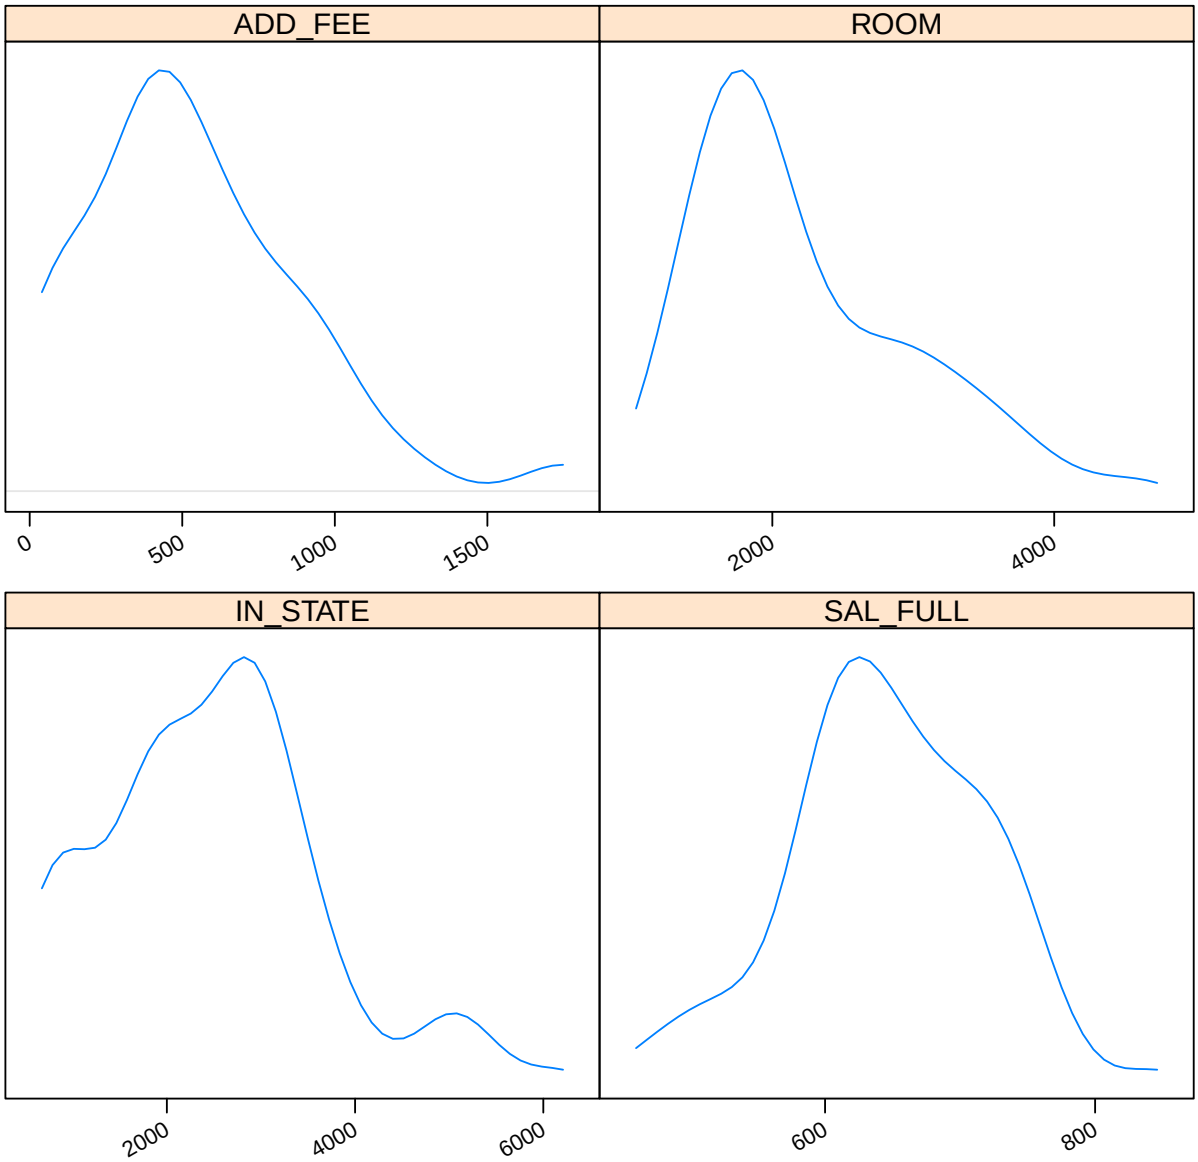


```
marginal.plot(log(subset(df.pub, select = c(ADD_FEE,
    ROOM, IN_STATE, SAL_FULL))))
```

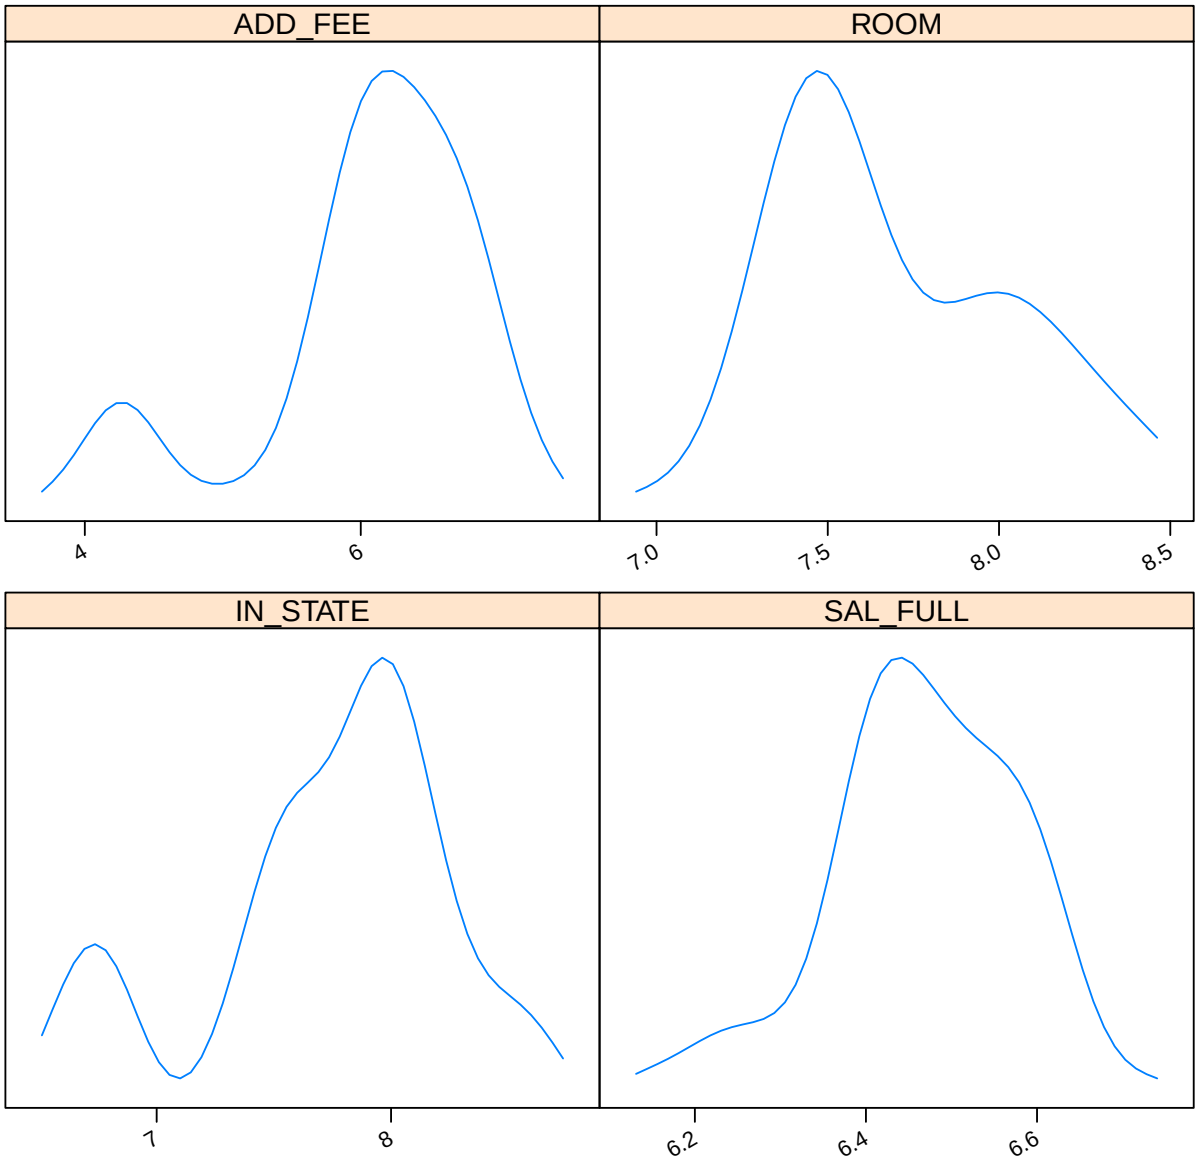


```
# После логарифмирования появилась
# мультимодальность, хотя распределения
# стали на вид немного более
# симметричными.  Я все-таки хочу
# оставить логарифмирование, потому что
# это денежные признаки Но потом мы
# проверим и без него
# Итого
fit1 <- lm(NEW10 ~ AVRCOMB + FULLTIME + log(IN_STATE) +
    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
## -22.770  -3.407   1.111   3.588  15.071
##
## Coefficients:
##                 Estimate Std. Error t value Pr(>|t|)
## (Intercept)   -4.397e+01  8.490e+01  -0.518  0.60828
## AVRCOMB        1.469e-01  2.823e-02   5.203 1.31e-05 ***
## FULLTIME      -2.458e-04  3.797e-04  -0.647  0.52227
## log(IN_STATE) -9.057e+00  2.646e+00  -3.422  0.00181 **
## log(ROOM)     -4.011e+00  4.082e+00  -0.982  0.33375
## log(ADD_FEE)  -3.651e+00  1.628e+00  -2.242  0.03251 *
## log(SAL_FULL)  1.114e+01  1.459e+01   0.764  0.45090
## PH_D          -4.984e-01  2.842e-01  -1.754  0.08965 .
## GRADUAT        2.645e-01  1.469e-01   1.801  0.08173 .
## NUM_FULL       1.225e-02  1.172e-02   1.045  0.30431
## ---
## Signif. codes:
## 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 7.755 on 30 degrees of freedom
## Multiple R-squared:  0.7874,Adjusted R-squared:  0.7236
## F-statistic: 12.35 on 9 and 30 DF,  p-value: 6.861e-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)    4.531e+01  1.128e+02   0.402 0.690693
## FULLTIME      -3.024e-04  5.150e-04  -0.587 0.561361
## log(IN_STATE) -1.313e+01  3.430e+00  -3.829 0.000586 ***
## log(ROOM)     -2.312e+00  5.521e+00  -0.419 0.678299
## log(ADD_FEE)  -4.263e+00  2.204e+00  -1.934 0.062256 .
## log(SAL_FULL)  1.671e+01  1.974e+01   0.846 0.403798
## PH_D          -2.902e-01  3.818e-01  -0.760 0.452957
## GRADUAT        7.369e-01  1.566e-01   4.705    5e-05 ***
## NUM_FULL       1.917e-02  1.580e-02   1.213 0.234185
## ---
## Signif. codes:
## 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 10.52 on 31 degrees of freedom
## Multiple R-squared:  0.5956,Adjusted R-squared:  0.4912
## F-statistic: 5.706 on 8 and 31 DF,  p-value: 0.0001718

# 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
## -26.2271  -5.1813  -0.4403   6.7982  19.5760
##
## Coefficients:
##               Estimate Std. Error t value Pr(>|t|)
## (Intercept)   113.0619    28.2689   4.000 0.000302 ***
## log(IN_STATE) -13.1875     3.2280  -4.085 0.000235 ***
```

```
## log(ADD_FEE)   -4.8304     2.1489  -2.248 0.030801 *
## GRADUAT         0.8187     0.1376   5.949 8.14e-07 ***
## ---
## Signif. codes:
## 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 10.53 on 36 degrees of freedom
## Multiple R-squared:   0.53,Adjusted R-squared:  0.4908
## F-statistic: 13.53 on 3 and 36 DF,  p-value: 4.559e-06

fit2.aic <- stepAIC(fit2)

## Start:  AIC=196.08
## 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     19.41 3451.4 194.31
## - FULLTIME       1     38.17 3470.2 194.52
## - PH_D           1     63.96 3496.0 194.82
## - log(SAL_FULL)  1     79.32 3511.3 195.00
## - NUM_FULL       1    162.97 3595.0 195.94
## <none>                       3432.0 196.08
## - log(ADD_FEE)   1    414.20 3846.2 198.64
## - log(IN_STATE)  1   1623.10 5055.1 209.57
## - GRADUAT        1   2450.49 5882.5 215.63
##
## Step:  AIC=194.31
## NEW10 ~ FULLTIME + log(IN_STATE) + log(ADD_FEE) + log(SAL_FULL) +
##     PH_D + GRADUAT + NUM_FULL
##
##                 Df Sum of Sq    RSS    AIC
## - FULLTIME       1     36.92 3488.4 192.73
## - log(SAL_FULL)  1     60.03 3511.5 193.00
## - PH_D           1     61.34 3512.8 193.01
## <none>                       3451.4 194.31
## - NUM_FULL       1    193.54 3645.0 194.49
## - log(ADD_FEE)   1    451.12 3902.6 197.22
## - log(IN_STATE)  1   1729.29 5180.7 208.55
## - GRADUAT        1   2629.10 6080.5 214.96
##
## Step:  AIC=192.73
## NEW10 ~ log(IN_STATE) + log(ADD_FEE) + log(SAL_FULL) + PH_D +
##     GRADUAT + NUM_FULL
##
##                 Df Sum of Sq    RSS    AIC
## - PH_D           1     42.66 3531.0 191.22
## - log(SAL_FULL)  1     65.23 3553.6 191.47
```

```
## <none>                        3488.4 192.73
## - NUM_FULL       1    250.29 3738.6 193.50
## - log(ADD_FEE)   1    433.03 3921.4 195.41
## - log(IN_STATE)  1   1702.06 5190.4 206.63
## - GRADUAT        1   2592.19 6080.5 212.96
##
## Step:  AIC=191.22
## NEW10 ~ log(IN_STATE) + log(ADD_FEE) + log(SAL_FULL) + GRADUAT +
##     NUM_FULL
##
##                 Df Sum of Sq    RSS    AIC
## - log(SAL_FULL)  1     59.98 3591.0 189.89
## <none>                        3531.0 191.22
## - NUM_FULL       1    212.33 3743.3 191.55
## - log(ADD_FEE)   1    458.20 3989.2 194.10
## - log(IN_STATE)  1   1724.25 5255.3 205.12
## - GRADUAT        1   2550.89 6081.9 210.97
##
## Step:  AIC=189.89
## NEW10 ~ log(IN_STATE) + log(ADD_FEE) + GRADUAT + NUM_FULL
##
##                 Df Sum of Sq    RSS    AIC
## <none>                        3591.0 189.89
## - NUM_FULL       1     397.4 3988.4 192.09
## - log(ADD_FEE)   1     446.4 4037.4 192.58
## - log(IN_STATE)  1    1664.3 5255.3 203.12
## - GRADUAT        1    3291.4 6882.4 213.91
```

```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
## -22.9871  -5.6649  -0.5082   5.3076  23.9919
##
## Coefficients:
##                 Estimate Std. Error t value Pr(>|t|)
## (Intercept)   102.452608  27.733017   3.694 0.000748 ***
## log(IN_STATE) -12.574064   3.121998  -4.028 0.000288 ***
## log(ADD_FEE)   -4.344059   2.082633  -2.086 0.044348 *
## GRADUAT         0.765564   0.135166   5.664 2.14e-06 ***
## NUM_FULL        0.014231   0.007231   1.968 0.057016 .
## ---
## Signif. codes:
```

```
## 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 10.13 on 35 degrees of freedom
## Multiple R-squared:  0.5768,Adjusted R-squared:  0.5285
## F-statistic: 11.93 on 4 and 35 DF,  p-value: 3.23e-06

# Акаике предлагает оставить признак
# NUM_FULL.  Отличники поступают туда
# еще, где народу побольше.
# Посравниваю-ка я модели...
AIC(fit2.manual, fit2.aic)

##             df      AIC
## fit2.manual  5 307.6059
## fit2.aic     6 305.4073

# 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 3988.4
## 2     35 3591.0  1    397.42 3.8735 0.05702 .
## ---
## 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)
## NEW10          1.0000000   -0.25000604   0.11170368
## log(IN_STATE) -0.2500060    1.00000000  -0.15425172
## log(ADD_FEE)   0.1117037   -0.15425172   1.00000000
## GRADUAT        0.5449545    0.26450468   0.41064855
## NUM_FULL       0.3516683   -0.02384413  -0.02151739
##                 GRADUAT    NUM_FULL
## NEW10         0.5449545  0.35166826
## log(IN_STATE) 0.2645047 -0.02384413
## log(ADD_FEE)  0.4106486 -0.02151739
## GRADUAT       1.0000000  0.15156033
## NUM_FULL      0.1515603  1.00000000
```

```r
levelplot(cor(fit2.aic$model)^2, par.settings = list(regions = list(col = colorRamp
    scales = list(x = list(rot = 90)), xlab = "",
    ylab = "")
```

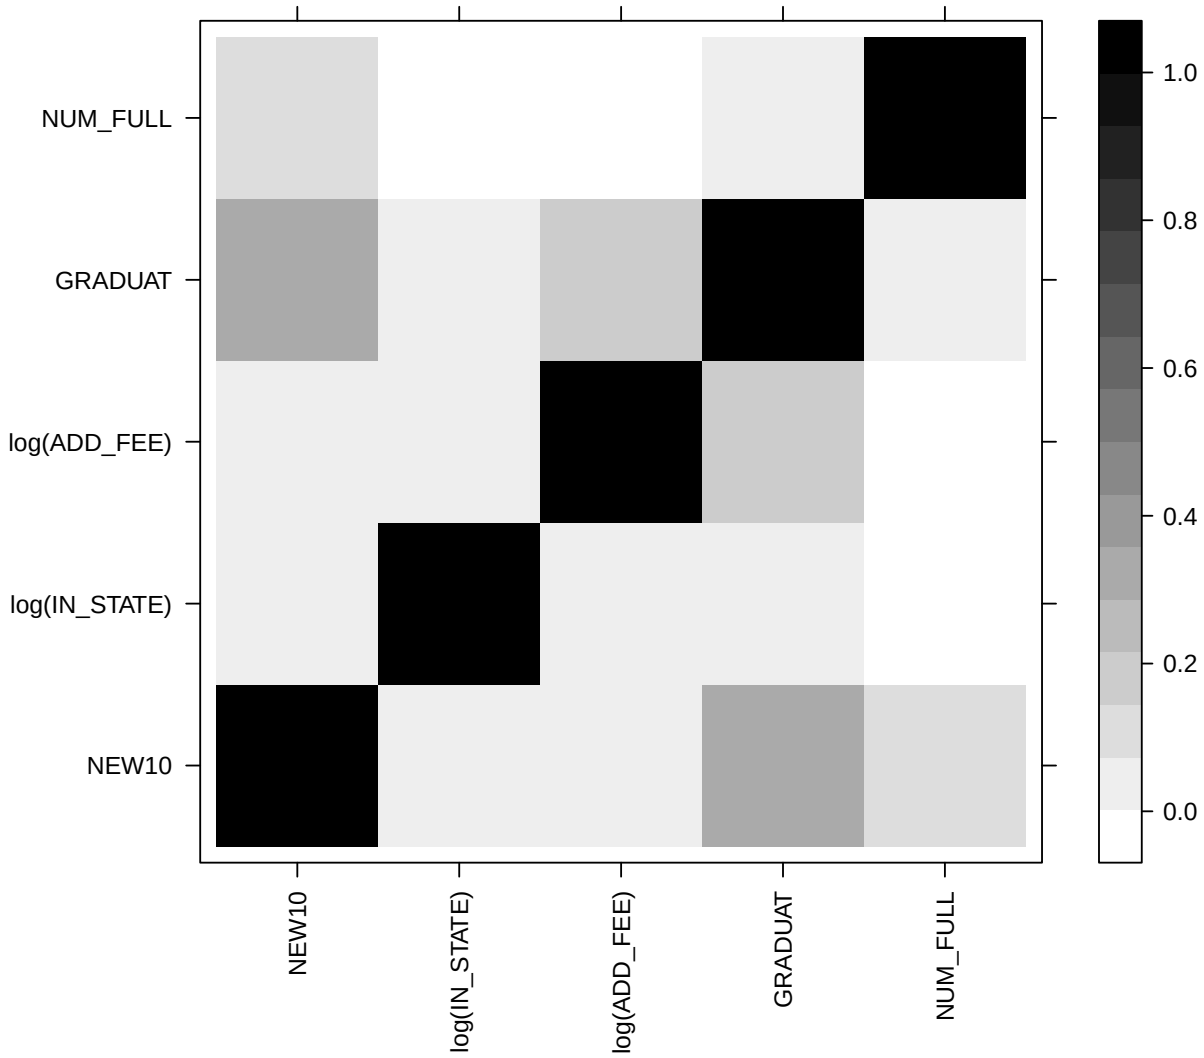


```r
summary(fit2.aic)

##
## Call:
## lm(formula = NEW10 ~ log(IN_STATE) + log(ADD_FEE) + GRADUAT +
##     NUM_FULL, data = df.pub)
##
## Residuals:
##      Min       1Q   Median       3Q      Max
## -22.9871  -5.6649  -0.5082   5.3076  23.9919
##
```

```
## Coefficients:
##                 Estimate Std. Error t value Pr(>|t|)
## (Intercept)   102.452608  27.733017   3.694 0.000748 ***
## log(IN_STATE) -12.574064   3.121998  -4.028 0.000288 ***
## log(ADD_FEE)   -4.344059   2.082633  -2.086 0.044348 *
## GRADUAT         0.765564   0.135166   5.664 2.14e-06 ***
## NUM_FULL        0.014231   0.007231   1.968 0.057016 .
## ---
## Signif. codes:
## 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 10.13 on 35 degrees of freedom
## Multiple R-squared:  0.5768,Adjusted R-squared:  0.5285
## F-statistic: 11.93 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: 135.5141

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

##
## Error estimation of 'lm' using 35-fold cross validation: 130.0471

# 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
## -24.0914  -4.6808   0.5468   3.5763  24.7934
##
## Coefficients:
##              Estimate Std. Error t value Pr(>|t|)
## (Intercept) -1.866977   7.509751  -0.249 0.805118
## IN_STATE    -0.005280   0.001417  -3.726 0.000685 ***
## ADD_FEE     -0.005985   0.005486  -1.091 0.282694
## GRADUAT      0.726085   0.144096   5.039 1.43e-05 ***
## NUM_FULL     0.015331   0.007459   2.055 0.047376 *
## ---
## Signif. codes:
## 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 10.45 on 35 degrees of freedom
## Multiple R-squared:  0.5498,Adjusted R-squared:  0.4984
## F-statistic: 10.69 on 4 and 35 DF,  p-value: 9.126e-06
```

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

```
##           df      AIC
## fit.nolog  6 307.8804
## fit2.aic   6 305.4073
```

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

4.3.1 Advertising, окончательный результат

```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      0.19 170.12 -20.363
## <none>                         169.93 -18.586
## - TV:Newspaper     1      4.37 174.30 -15.511
## - TV:Radio         1    349.71 519.64 202.965
##
## Step:  AIC=-20.36
## Sales ~ TV + Radio + Newspaper + TV:Radio + TV:Newspaper
##
##                 Df Sum of Sq    RSS     AIC
## <none>                       170.12 -20.363
## - TV:Newspaper  1      4.19 174.31 -17.494
## - TV:Radio      1    352.83 522.95 202.234
```

```r
summary(laic)
```

```
##
## Call:
## lm(formula = Sales ~ TV + Radio + Newspaper + TV:Radio + TV:Newspaper,
##     data = Advertising)
##
## Residuals:
##     Min      1Q  Median      3Q     Max
## -5.9019 -0.3818  0.1937  0.5741  1.4839
##
## Coefficients:
##                Estimate Std. Error t value Pr(>|t|)
## (Intercept)   6.541e+00  2.652e-01  24.668   <2e-16 ***
## TV            2.035e-02  1.605e-03  12.675   <2e-16 ***
## Radio         2.018e-02  9.734e-03   2.073   0.0395 *
## Newspaper     1.342e-02  6.377e-03   2.105   0.0366 *
## TV:Radio      1.136e-03  5.664e-05  20.059   <2e-16 ***
## TV:Newspaper -7.719e-05  3.531e-05  -2.187   0.0300 *
## ---
## Signif. codes:
## 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 0.9364 on 194 degrees of freedom
## Multiple R-squared:  0.9686,Adjusted R-squared:  0.9678
## F-statistic:  1197 on 5 and 194 DF,  p-value: < 2.2e-16
```

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

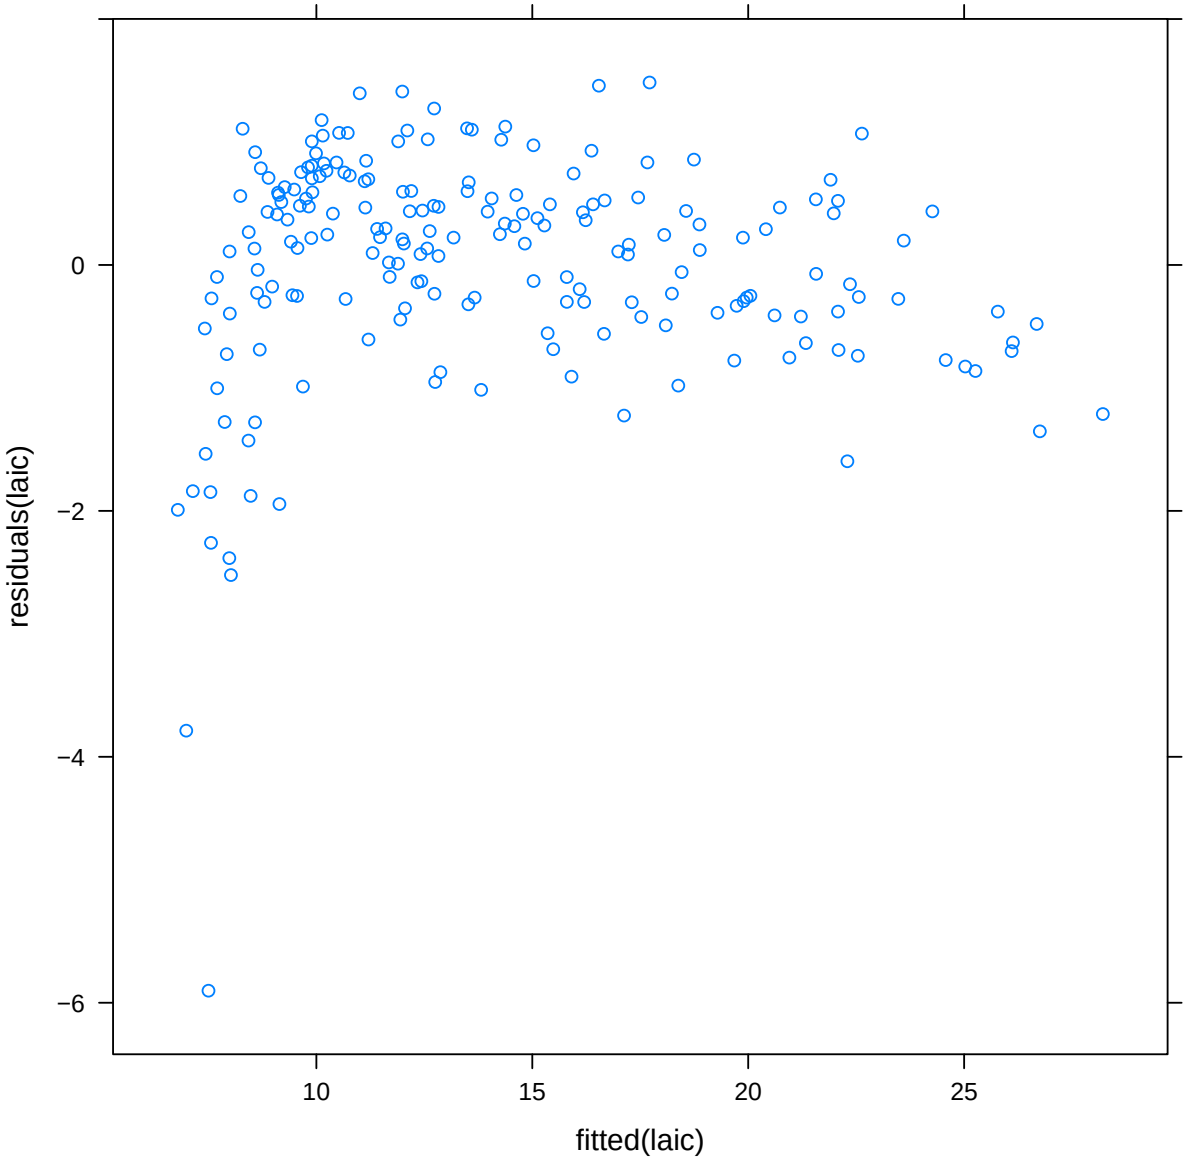


```
lsq <- lm(Sales ~ poly(TV, Radio, Newspaper,
    degree = 2), data = Advertising)
summary(lsq)

##
## Call:
## lm(formula = Sales ~ poly(TV, Radio, Newspaper, degree = 2),
##     data = Advertising)
##
## Residuals:
##     Min      1Q  Median      3Q     Max
## -4.6507 -0.2941 -0.0060  0.3830  1.4378
##
## Coefficients:
##                                                Estimate
```

```
## (Intercept)                                      13.94105
## poly(TV, Radio, Newspaper, degree = 2)1.0.0  53.73032
## poly(TV, Radio, Newspaper, degree = 2)2.0.0  -9.97989
## poly(TV, Radio, Newspaper, degree = 2)0.1.0  40.10484
## poly(TV, Radio, Newspaper, degree = 2)1.1.0 280.35751
## poly(TV, Radio, Newspaper, degree = 2)0.2.0   0.29727
## poly(TV, Radio, Newspaper, degree = 2)0.0.1   0.94373
## poly(TV, Radio, Newspaper, degree = 2)1.0.1 -16.93577
## poly(TV, Radio, Newspaper, degree = 2)0.1.1   5.31882
## poly(TV, Radio, Newspaper, degree = 2)0.0.2   0.10711
##                                              Std. Error
## (Intercept)                                     0.04806
## poly(TV, Radio, Newspaper, degree = 2)1.0.0    0.62580
## poly(TV, Radio, Newspaper, degree = 2)2.0.0    0.63251
## poly(TV, Radio, Newspaper, degree = 2)0.1.0    0.67044
## poly(TV, Radio, Newspaper, degree = 2)1.1.0    9.65318
## poly(TV, Radio, Newspaper, degree = 2)0.2.0    0.64859
## poly(TV, Radio, Newspaper, degree = 2)0.0.1    0.74141
## poly(TV, Radio, Newspaper, degree = 2)1.0.1    8.84414
## poly(TV, Radio, Newspaper, degree = 2)0.1.1   10.95328
## poly(TV, Radio, Newspaper, degree = 2)0.0.2    0.65997
##                                              t value
## (Intercept)                                  290.083
## poly(TV, Radio, Newspaper, degree = 2)1.0.0  85.858
## poly(TV, Radio, Newspaper, degree = 2)2.0.0 -15.778
## poly(TV, Radio, Newspaper, degree = 2)0.1.0  59.819
## poly(TV, Radio, Newspaper, degree = 2)1.1.0  29.043
## poly(TV, Radio, Newspaper, degree = 2)0.2.0   0.458
## poly(TV, Radio, Newspaper, degree = 2)0.0.1   1.273
## poly(TV, Radio, Newspaper, degree = 2)1.0.1  -1.915
## poly(TV, Radio, Newspaper, degree = 2)0.1.1   0.486
## poly(TV, Radio, Newspaper, degree = 2)0.0.2   0.162
##                                              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: 0.6203 on 190 degrees of freedom
```

```
## Multiple R-squared:  0.9865,Adjusted R-squared:  0.9859
## F-statistic:  1543 on 9 and 190 DF,  p-value: < 2.2e-16

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

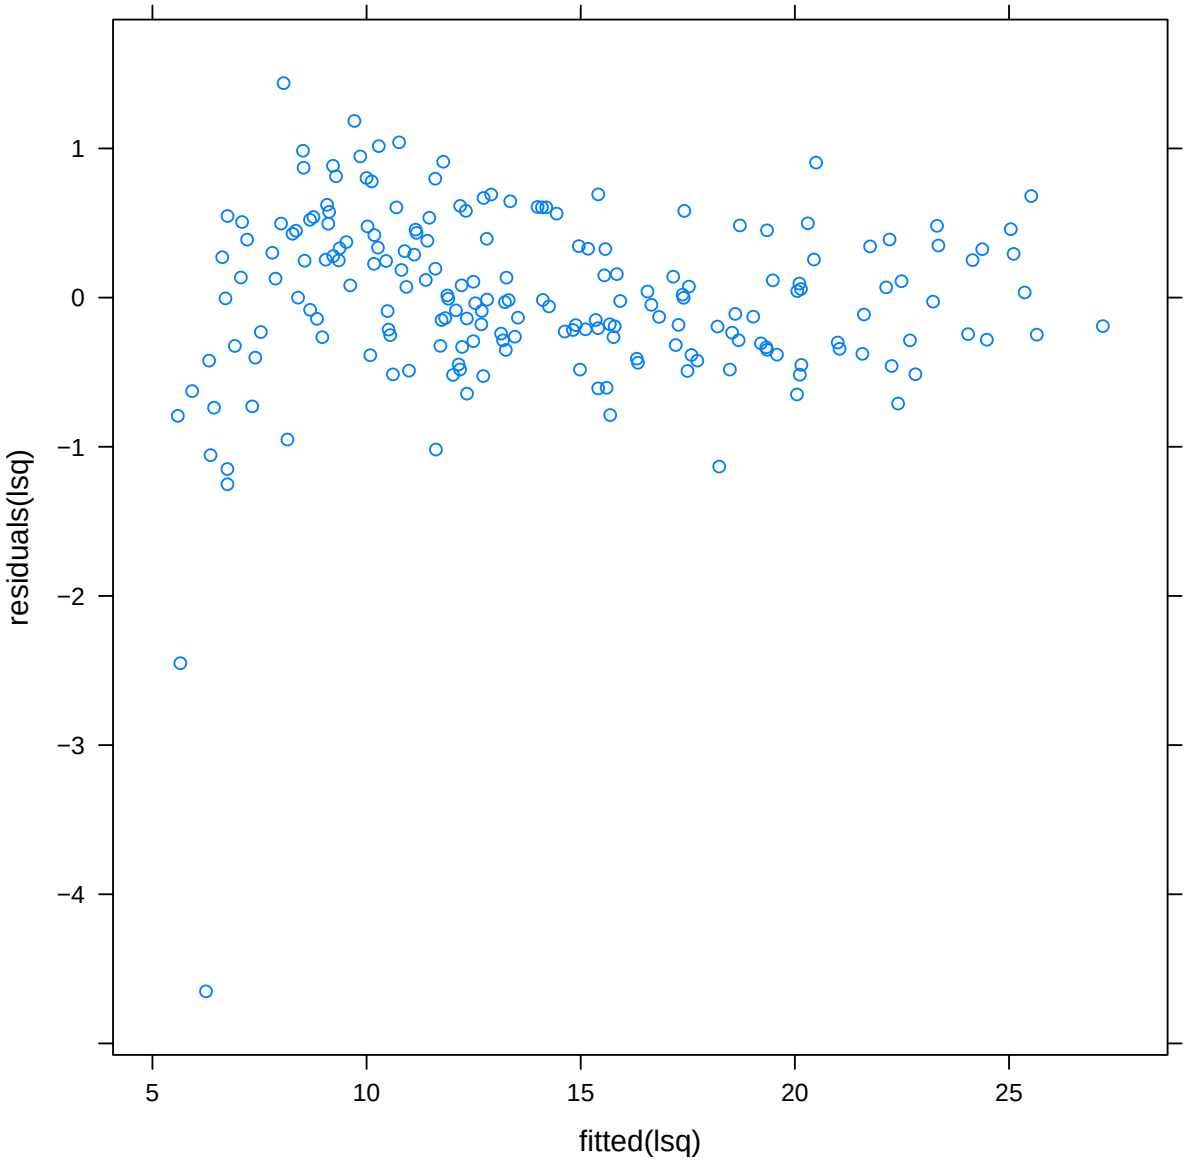


```
lsqaic <- stepAIC(lsq)

## Start:  AIC=-181.3
## Sales ~ poly(TV, Radio, Newspaper, degree = 2)
##
##                                          Df Sum of Sq
## <none>
## - poly(TV, Radio, Newspaper, degree = 2)  9      5344
##                                            RSS    AIC
## <none>                                    73.1 -181.3
```

```
## - poly(TV, Radio, Newspaper, degree = 2) 5417.1  661.8

summary(lsqaic)

##
## Call:
## lm(formula = Sales ~ poly(TV, Radio, Newspaper, degree = 2),
##     data = Advertising)
##
## Residuals:
##     Min      1Q  Median      3Q     Max
## -4.6507 -0.2941 -0.0060  0.3830  1.4378
##
## Coefficients:
##                                              Estimate
## (Intercept)                                  13.94105
## poly(TV, Radio, Newspaper, degree = 2)1.0.0  53.73032
## poly(TV, Radio, Newspaper, degree = 2)2.0.0  -9.97989
## poly(TV, Radio, Newspaper, degree = 2)0.1.0  40.10484
## poly(TV, Radio, Newspaper, degree = 2)1.1.0 280.35751
## poly(TV, Radio, Newspaper, degree = 2)0.2.0   0.29727
## poly(TV, Radio, Newspaper, degree = 2)0.0.1   0.94373
## poly(TV, Radio, Newspaper, degree = 2)1.0.1 -16.93577
## poly(TV, Radio, Newspaper, degree = 2)0.1.1   5.31882
## poly(TV, Radio, Newspaper, degree = 2)0.0.2   0.10711
##                                             Std. Error
## (Intercept)                                    0.04806
## poly(TV, Radio, Newspaper, degree = 2)1.0.0    0.62580
## poly(TV, Radio, Newspaper, degree = 2)2.0.0    0.63251
## poly(TV, Radio, Newspaper, degree = 2)0.1.0    0.67044
## poly(TV, Radio, Newspaper, degree = 2)1.1.0    9.65318
## poly(TV, Radio, Newspaper, degree = 2)0.2.0    0.64859
## poly(TV, Radio, Newspaper, degree = 2)0.0.1    0.74141
## poly(TV, Radio, Newspaper, degree = 2)1.0.1    8.84414
## poly(TV, Radio, Newspaper, degree = 2)0.1.1   10.95328
## poly(TV, Radio, Newspaper, degree = 2)0.0.2    0.65997
##                                             t value
## (Intercept)                                 290.083
## poly(TV, Radio, Newspaper, degree = 2)1.0.0  85.858
## poly(TV, Radio, Newspaper, degree = 2)2.0.0 -15.778
## poly(TV, Radio, Newspaper, degree = 2)0.1.0  59.819
## poly(TV, Radio, Newspaper, degree = 2)1.1.0  29.043
## poly(TV, Radio, Newspaper, degree = 2)0.2.0   0.458
## poly(TV, Radio, Newspaper, degree = 2)0.0.1   1.273
## poly(TV, Radio, Newspaper, degree = 2)1.0.1  -1.915
## poly(TV, Radio, Newspaper, degree = 2)0.1.1   0.486
## poly(TV, Radio, Newspaper, degree = 2)0.0.2   0.162
##                                             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: 0.6203 on 190 degrees of freedom
## Multiple R-squared:  0.9865,Adjusted R-squared:  0.9859
## F-statistic:  1543 on 9 and 190 DF,  p-value: < 2.2e-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
## -4.9949 -0.2969 -0.0066  0.3798  1.1686
##
## Coefficients:
##               Estimate Std. Error t value Pr(>|t|)
## (Intercept)  5.137e+00  1.927e-01  26.663  < 2e-16 ***
## TV           5.092e-02  2.232e-03  22.810  < 2e-16 ***
## Radio        3.516e-02  5.901e-03   5.959 1.17e-08 ***
## I(TV^2)     -1.097e-04  6.893e-06 -15.920  < 2e-16 ***
## TV:Radio     1.077e-03  3.466e-05  31.061  < 2e-16 ***
## ---
## Signif. codes:
## 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## Residual standard error: 0.6238 on 195 degrees of freedom
## Multiple R-squared:  0.986,Adjusted R-squared:  0.9857
## F-statistic:  3432 on 4 and 195 DF,  p-value: < 2.2e-16

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

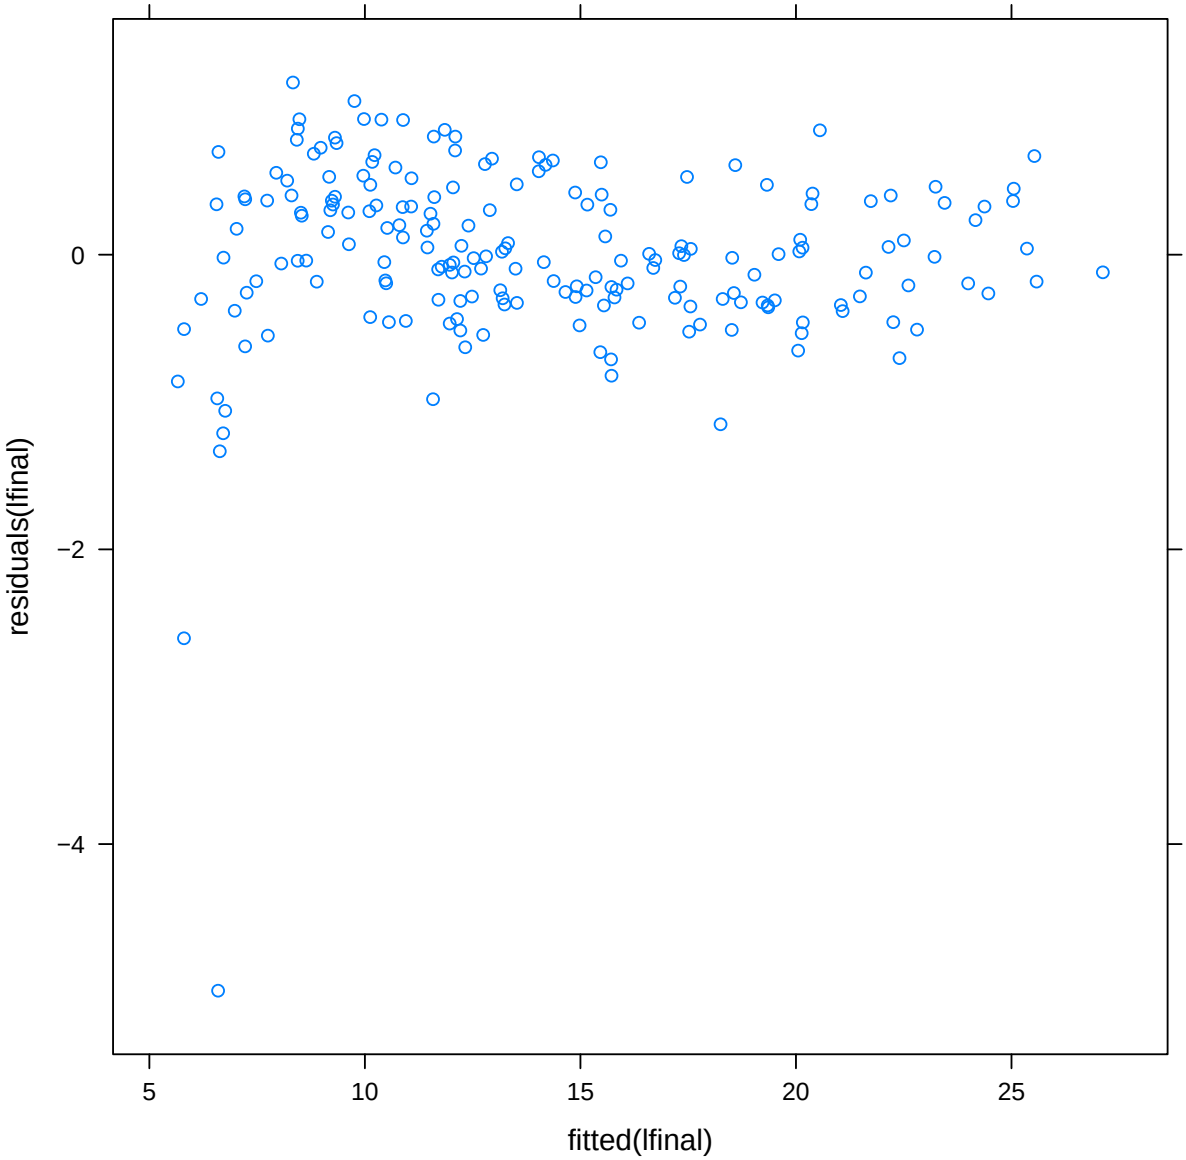


```
tune(lm, lfinal$call$formula, data = Advertising,
    tunecontrol = tune.control(sampling = "fix"))

##
## Error estimation of 'lm' using fixed training/validation set: 0.2684496

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

##
## Error estimation of 'lm' using fixed training/validation set: 1.965847

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

```
##
## Error estimation of 'lm' using fixed training/validation set: 1.061326

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

##
## Error estimation of 'lm' using fixed training/validation set: 0.7586386
```

5 Материалы с занятия 10 октября

Вспомогательнй код для классификации

```
library(MASS)  # AIC(), BIC(), lda(), qda()
library(lattice)  # xyplot(), densityplot()
library(latticeExtra)  # layer()

## Loading required package: RColorBrewer

library(ROCR)  # performance(), prediction()

## Loading required package: gplots
##
## Attaching package: 'gplots'
##
## The following object is masked from 'package:stats':
##
##    lowess
##
## Loading required package: methods

# library(caret) # specificity(),
# sensitivity()
library(nnet)  # multinom()
library(e1071)  # naiveBayes(), tune()
specificity <- caret:::specificity
sensitivity <- caret:::sensitivity
ROC <- function(predicted, actual, ...) {
    pred <- prediction(predicted, as.numeric(actual))
    roc <- performance(pred, measure = "tpr",
        x.measure = "fpr", ...)
    roc
}
xyplot.performance <- function(x, ...) {
    xyplot(x@y.values[[1]] ~ x@x.values[[1]],
        xlab = x@x.name, ylab = x@y.name,
        type = "l", ...) + layer_(abline(a = 0,
        b = 1, col = "red"))
```

```
}
AUC <- function(predicted, actual, ...) {
    pred <- prediction(predicted, as.numeric(actual))
    perf <- performance(pred, measure = "auc",
        ...)
    perf@y.values[[1]]
}
roc.opt <- function(predicted, actual, cutoff = NULL,
    measure = c("mean", "max", "err")) {
    pred <- prediction(predicted, as.numeric(actual))
    perf <- performance(pred, measure = "fpr",
        x.measure = "fnr")
    measure <- match.arg(measure)
    fpr <- perf@y.values[[1]]
    fnr <- perf@x.values[[1]]
    npos <- pred@n.pos[[1]]
    nneg <- pred@n.neg[[1]]
    err <- (fpr * nneg + fnr * npos)/(npos +
        nneg)
    error.rate <- switch(measure, mean = (fpr +
        fnr)/2, max = pmax(fpr, fnr), err = err)
    if (is.null(cutoff)) {
        i <- which.min(error.rate)
    } else {
        i <- which.min(abs(perf@alpha.values[[1]] -
            cutoff))
    }
    list(cutoff = perf@alpha.values[[1]][i],
        fpr = fpr[i], fnr = fnr[i], err = err[i],
        error.rate = error.rate[i])
}
simple.predict.glm <- function(x, newdata,
    ...) {
    response <- predict(x, newdata, type = "response",
        ...)
    factor(levels(x$model[, 1])[1 + as.integer(response >
        0.5)])
}
my.predict.glm <- function(x, newdata = x$data,
    ..., measure = "max") {
    opt <- roc.opt(fitted(x), as.numeric(x$model[,
        1]), measure = measure)
    cutoff <- opt$cutoff
    factor(as.integer(predict(x, newdata = newdata,
        type = "response") > cutoff), labels = levels(x$model[,
        1]))
}
error.fun.max <- function(true, predicted) {
```

```
    1 - min(sensitivity(predicted, true),
        specificity(predicted, true))
}
error.fun.mean <- function(true, predicted) {
    1 - mean(sensitivity(predicted, true),
        specificity(predicted, true))
}
my.lda <- function(x, data, ...) {
    out <- lda(x, data, ...)
    out$data <- data
    out
}
my.qda <- function(x, data, ...) {
    out <- qda(x, data, ...)
    out$data <- data
    out
}
simple.predict.da <- function(...) predict(...)$class
my.predict.da <- function(x, newdata, cutoff.data = x$data,
    ..., measure = "max") {
    response <- model.frame(x$terms, cutoff.data)[,
        1]
    opt <- roc.opt(predict(x, cutoff.data)$posterior[,
        2], as.numeric(response), measure = measure)
    cutoff <- opt$cutoff
    factor(as.integer(predict(x, newdata = newdata)$posterior[,
        2] > cutoff), labels = levels(response))
}
```

5.1 LDA и tune

```
library(MASS)
library(lattice)
library(latticeExtra)
library(ROCR)
library(e1071)
ld <- lda(Species ~ ., data = iris)
ld

## Call:
## lda(Species ~ ., data = iris)
##
## Prior probabilities of groups:
##     setosa versicolor  virginica
##  0.3333333  0.3333333  0.3333333
##
```

```
## Group means:
##            Sepal.Length Sepal.Width Petal.Length
## setosa            5.006       3.428        1.462
## versicolor        5.936       2.770        4.260
## virginica         6.588       2.974        5.552
##            Petal.Width
## setosa           0.246
## versicolor       1.326
## virginica        2.026
##
## Coefficients of linear discriminants:
##                     LD1         LD2
## Sepal.Length  0.8293776  0.02410215
## Sepal.Width   1.5344731  2.16452123
## Petal.Length -2.2012117 -0.93192121
## Petal.Width  -2.8104603  2.83918785
##
## Proportion of trace:
##    LD1    LD2
## 0.9912 0.0088
```

```
train.idx <- sample(nrow(iris), size = nrow(iris) *
    0.6)
iris.train <- iris[train.idx, ]
iris.test <- iris[-train.idx, ]
ld <- lda(Species ~ ., data = iris.train,
    prior = c(1/3, 1/3, 1/3))
ld
```

```
## Call:
## lda(Species ~ ., data = iris.train, prior = c(1/3, 1/3, 1/3))
##
## Prior probabilities of groups:
##     setosa versicolor  virginica
##  0.3333333  0.3333333  0.3333333
##
## Group means:
##            Sepal.Length Sepal.Width Petal.Length
## setosa         4.993548    3.429032     1.441935
## versicolor     5.951724    2.762069     4.275862
## virginica      6.396667    2.880000     5.403333
##            Petal.Width
## setosa       0.2451613
## versicolor   1.3137931
## virginica    2.0133333
##
## Coefficients of linear discriminants:
##                    LD1       LD2
```

```
## Sepal.Length  1.084260  0.570387
## Sepal.Width   1.163914 -1.784660
## Petal.Length -2.579978  1.225039
## Petal.Width  -2.420225 -3.933850
##
## Proportion of trace:
##    LD1    LD2
## 0.9903 0.0097
```

```
table(predicted = predict(ld, iris.test)$class,
    actual = iris.test$Species)
```

```
##             actual
## predicted    setosa versicolor virginica
##   setosa         19          0         0
##   versicolor      0         20         0
##   virginica       0          1        20
```

```
table(predicted = predict(ld, iris.test,
    prior = c(0.5, 0.25, 0.25))$class, actual = iris.test$Species)
```

```
##             actual
## predicted    setosa versicolor virginica
##   setosa         19          0         0
##   versicolor      0         20         0
##   virginica       0          1        20
```

```
cm <- table(predicted = predict(ld, iris.test)$class,
    actual = iris.test$Species)
chisq.test(cm)
```

```
##
##  Pearson's Chi-squared test
##
## data:  cm
## X-squared = 114.4218, df = 4, p-value < 2.2e-16
```

```
# test-train
tune(lda, Species ~ ., prior = c(1/3, 1/3,
    1/3), data = iris, predict.func = function(...) predict(...)$class,
    tunecontrol = tune.control(sampling = "fix",
        fix = 2/3))
```

```
##
## Error estimation of 'lda' using fixed training/validation set: 0
```

```
simple.predict.da <- function(...) predict(...)$class
# bootstrap
tune(lda, Species ~ ., prior = c(1/3, 1/3,
    1/3), data = iris, predict.func = simple.predict.da,
    tunecontrol = tune.control(sampling = "bootstrap",
        nboot = 10, boot.size = 9/10))
```

```
##
## Error estimation of 'lda' using bootstrapping: 0.0296425

# leave-one-out
tune(lda, Species ~ ., prior = c(1/3, 1/3,
    1/3), data = iris, predict.func = simple.predict.da,
    tunecontrol = tune.control(sampling = "cross",
        cross = nrow(iris)))

##
## Error estimation of 'lda' using leave-one-out: 0.02

# cross-validationi (default)
tn <- tune(lda, Species ~ ., prior = c(1/3,
    1/3, 1/3), data = iris, predict.func = simple.predict.da,
    tunecontrol = tune.control(sampling = "cross",
        cross = 10))
tn$best.model

## Call:
## best.tune(lda, train.x = Species ~ ., data = iris, predict.func = simple.predict
##     tunecontrol = tune.control(sampling = "cross", cross = 10),
##     prior = c(1/3, 1/3, 1/3))
##
## Prior probabilities of groups:
##     setosa versicolor  virginica
##  0.3333333  0.3333333  0.3333333
##
## Group means:
##            Sepal.Length Sepal.Width Petal.Length
## setosa            5.006       3.428        1.462
## versicolor        5.936       2.770        4.260
## virginica         6.588       2.974        5.552
##            Petal.Width
## setosa           0.246
## versicolor       1.326
## virginica        2.026
##
## Coefficients of linear discriminants:
##                     LD1         LD2
## Sepal.Length  0.8293776  0.02410215
## Sepal.Width   1.5344731  2.16452123
## Petal.Length -2.2012117 -0.93192121
## Petal.Width  -2.8104603  2.83918785
##
## Proportion of trace:
##    LD1    LD2
## 0.9912 0.0088
```

```r
tn$performance

##   dummyparameter error dispersion
## 1              0  0.02 0.03220306

# tn$train.ind
# Naive Bayes
nb <- naiveBayes(Species ~ ., data = iris)
tn.nb <- tune(naiveBayes, Species ~ ., data = iris)
# multinomial regression
mln <- multinom(Species ~ ., data = iris,
    trace = FALSE)
tn.mln <- tune(multinom, Species ~ ., data = iris,
    trace = FALSE)
summary(mln)

## Call:
## multinom(formula = Species ~ ., data = iris, trace = FALSE)
##
## Coefficients:
##            (Intercept) Sepal.Length Sepal.Width
## versicolor    18.69037    -5.458424   -8.707401
## virginica    -23.83628    -7.923634  -15.370769
##            Petal.Length Petal.Width
## versicolor     14.24477   -3.097684
## virginica      23.65978   15.135301
##
## Std. Errors:
##            (Intercept) Sepal.Length Sepal.Width
## versicolor    34.97116     89.89215    157.0415
## virginica     35.76649     89.91153    157.1196
##            Petal.Length Petal.Width
## versicolor     60.19170    45.48852
## virginica      60.46753    45.93406
##
## Residual Deviance: 11.89973
## AIC: 31.89973

mln.aic <- stepAIC(mln)

## Start:  AIC=31.9
## Species ~ Sepal.Length + Sepal.Width + Petal.Length + Petal.Width
##
##                Df    AIC
## - Sepal.Length  2 29.267
## - Sepal.Width   2 31.498
## <none>            31.900
## - Petal.Width   2 39.773
## - Petal.Length  2 41.915
```

```
##
## Step:  AIC=29.27
## Species ~ Sepal.Width + Petal.Length + Petal.Width
##
##                 Df    AIC
## <none>             29.267
## - Sepal.Width    2 32.579
## - Petal.Length   2 39.399
## - Petal.Width    2 43.516
```

```r
summary(mln.aic)
```

```
## Call:
## multinom(formula = Species ~ Sepal.Width + Petal.Length + Petal.Width,
##     data = iris, trace = FALSE)
##
## Coefficients:
##            (Intercept) Sepal.Width Petal.Length Petal.Width
## versicolor    14.15646   -17.32240     14.09906   -2.695628
## virginica    -36.44078   -25.70717     21.98210   18.765796
##
## Std. Errors:
##            (Intercept) Sepal.Width Petal.Length Petal.Width
## versicolor    29.66211    47.48205     68.57820    39.08345
## virginica     32.18618    48.00257     68.76678    39.75433
##
## Residual Deviance: 13.26653
## AIC: 29.26653
```

5.2 Default

```r
library(MASS)
library(lattice)
library(latticeExtra)
library(ISLR)
source("class.R")
data(Default)
gl <- glm(default ~ balance + student, data = Default,
    family = binomial(link = "logit"))
Default.sorted <- Default[order(Default$balance),
    ]
xyplot(predict(gl, Default.sorted, type = "response") ~
    balance, groups = student, data = Default.sorted,
    type = "l", auto.key = list(corner = c(0,
        1), title = "Student", lines = TRUE,
        points = FALSE), xlab = "Credit Card Balance",
```

```
    ylab = "Default Rate") + layer_(panel.superpose(x = Default.sorted$default ==
    "Yes", panel.groups = function(x, y,
    ...) panel.abline(h = mean(x), ...),
    lty = "dashed", ...))
```

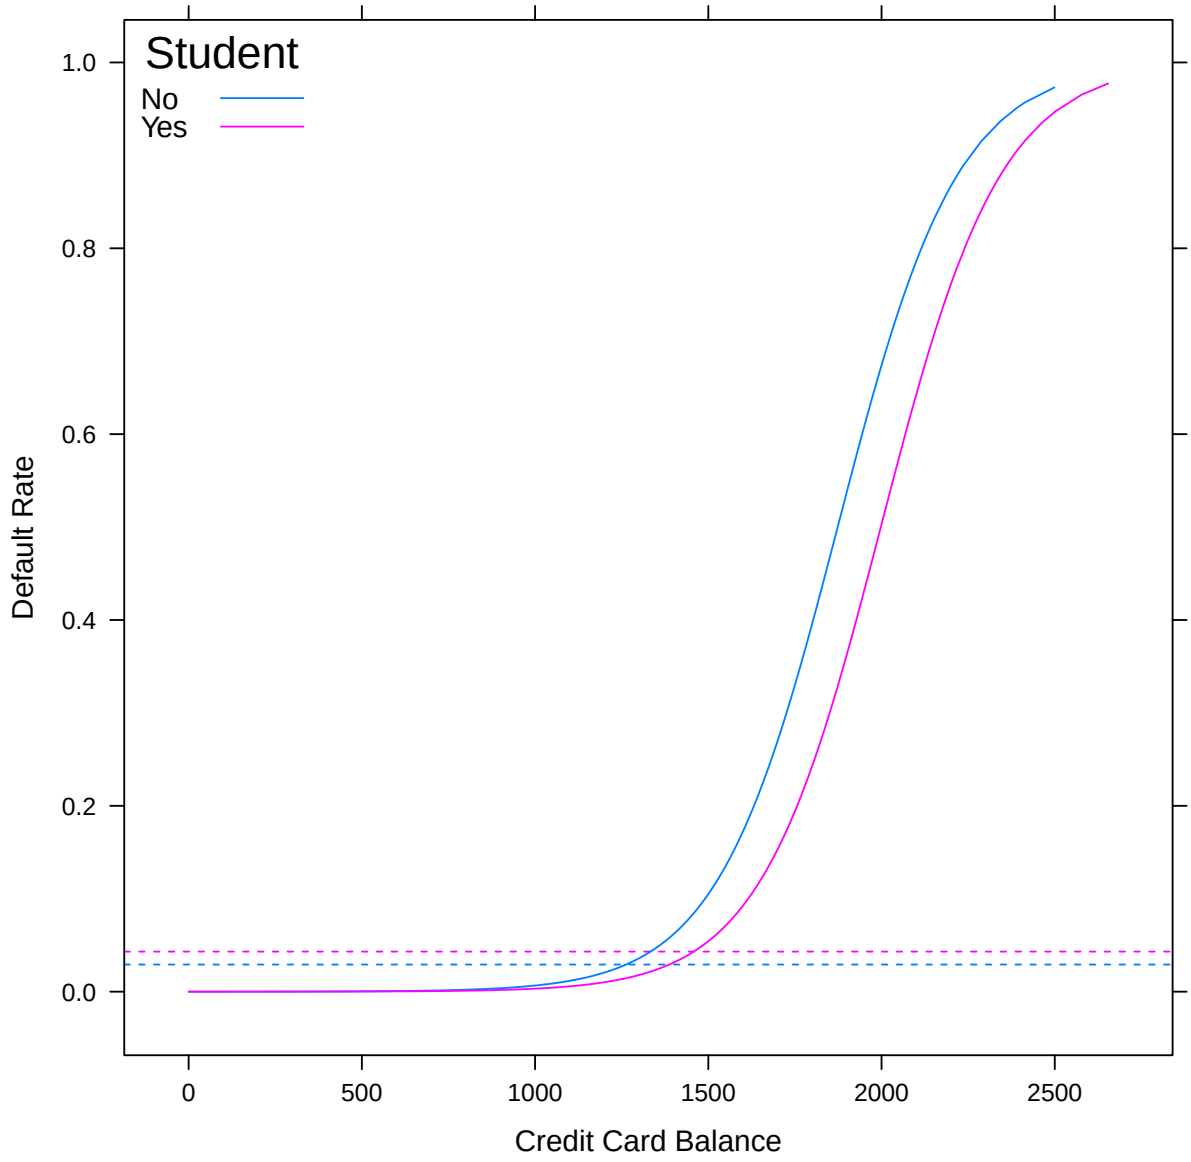


```
roc <- ROC(predict(gl, Default), Default$default)
plot(roc)
```

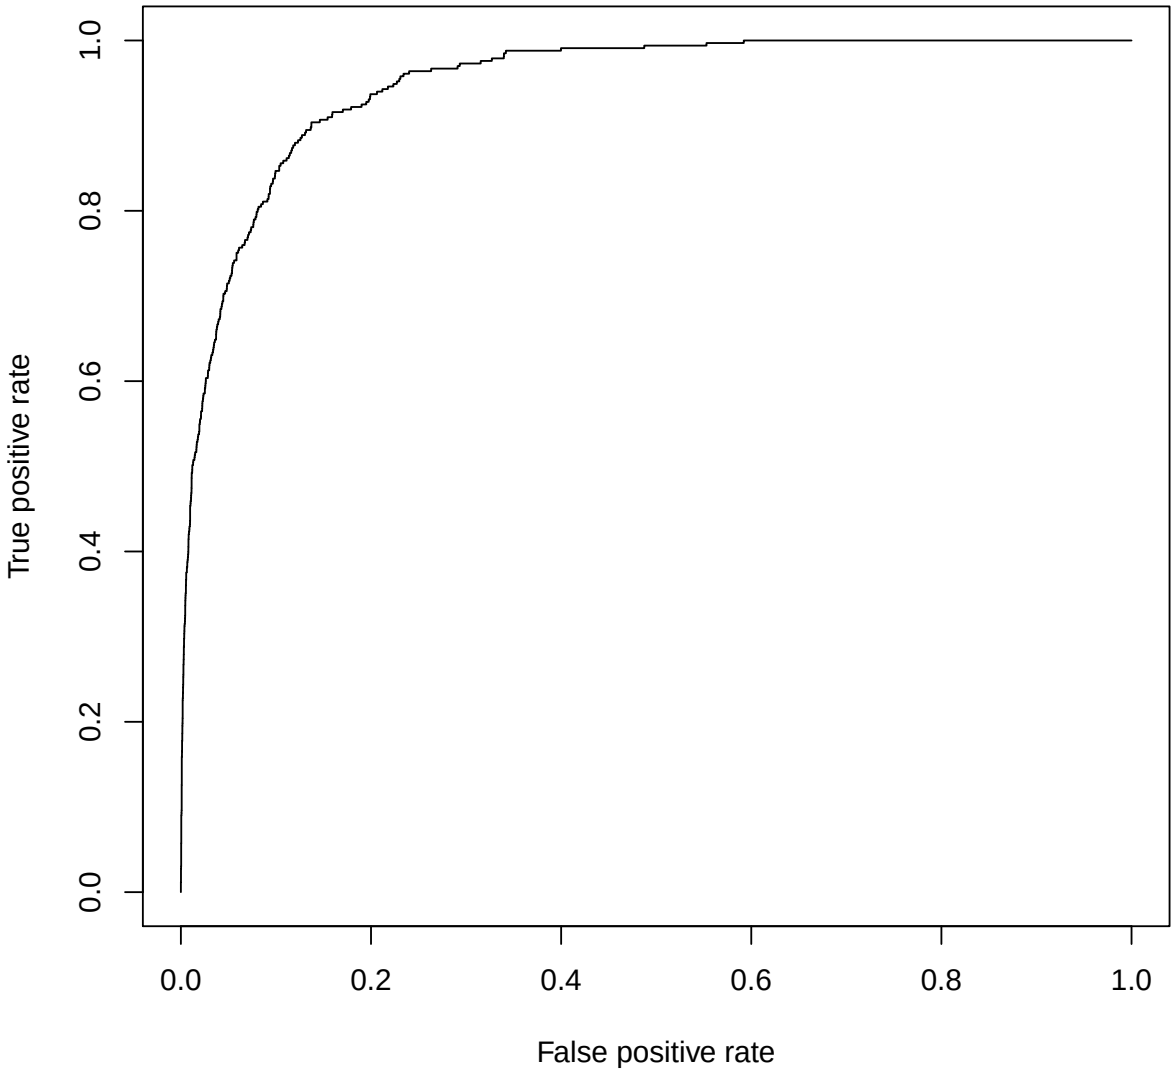


```
AUC(predict(gl, Default), Default$default)

## [1] 0.9495476

error.fun.auc <- function(true, predicted) {
    -AUC(predicted, true)
}
tune(glm, default ~ ., data = Default, family = binomial(link = "logit"),
    tunecontrol = tune.control(error.fun = error.fun.auc))

##
## Error estimation of 'glm' using 10-fold cross validation: -0.9502396

table(predicted = my.predict.glm(gl, measure = "max"),
    actual = Default$default)
```

```
##          actual
## predicted   No  Yes
##       No  8507   41
##       Yes 1160  292
```

```r
table(predicted = my.predict.glm(gl, measure = "mean"),
    actual = Default$default)
```

```
##          actual
## predicted   No  Yes
##       No  8340   33
##       Yes 1327  300
```

```r
table(predicted = my.predict.glm(gl, measure = "err"),
    actual = Default$default)
```

```
##          actual
## predicted   No  Yes
##       No  9613  209
##       Yes   54  124
```

```r
train <- sample(nrow(Default), size = 0.6 *
    nrow(Default))
gl <- glm(default ~ balance + student, data = Default,
    subset = train, family = binomial(link = "logit"))
table(predicted = my.predict.glm(gl, Default[-train,
    ], measure = "max"), actual = Default[-train,
    ]$default)
```

```
##          actual
## predicted   No  Yes
##       No  3402   18
##       Yes  470  110
```

```r
table(predicted = my.predict.glm(gl, Default[-train,
    ], measure = "mean"), actual = Default[-train,
    ]$default)
```

```
##          actual
## predicted   No  Yes
##       No  3390   16
##       Yes  482  112
```

```r
table(predicted = my.predict.glm(gl, Default[-train,
    ], measure = "err"), actual = Default[-train,
    ]$default)
```

```
##          actual
## predicted   No  Yes
##       No  3846   80
##       Yes   26   48
```

5.3 Smarket

```r
library(ISLR)
library(MASS)
data(Smarket)
gl <- glm(Direction ~ Volume + Lag1 + Lag2 +
    Lag3 + Lag4 + Lag5, data = Smarket, family = binomial(link = "logit"))
summary(gl)

##
## Call:
## glm(formula = Direction ~ Volume + Lag1 + Lag2 + Lag3 + Lag4 +
##     Lag5, family = binomial(link = "logit"), data = Smarket)
##
## Deviance Residuals:
##    Min      1Q  Median      3Q     Max
## -1.446  -1.203   1.065   1.145   1.326
##
## Coefficients:
##              Estimate Std. Error z value Pr(>|z|)
## (Intercept) -0.126000   0.240736  -0.523    0.601
## Volume       0.135441   0.158360   0.855    0.392
## Lag1        -0.073074   0.050167  -1.457    0.145
## Lag2        -0.042301   0.050086  -0.845    0.398
## Lag3         0.011085   0.049939   0.222    0.824
## Lag4         0.009359   0.049974   0.187    0.851
## Lag5         0.010313   0.049511   0.208    0.835
##
## (Dispersion parameter for binomial family taken to be 1)
##
##     Null deviance: 1731.2  on 1249  degrees of freedom
## Residual deviance: 1727.6  on 1243  degrees of freedom
## AIC: 1741.6
##
## Number of Fisher Scoring iterations: 3

source("class.R")
roc <- ROC(predict(gl), Smarket$Direction)
plot(roc)
```

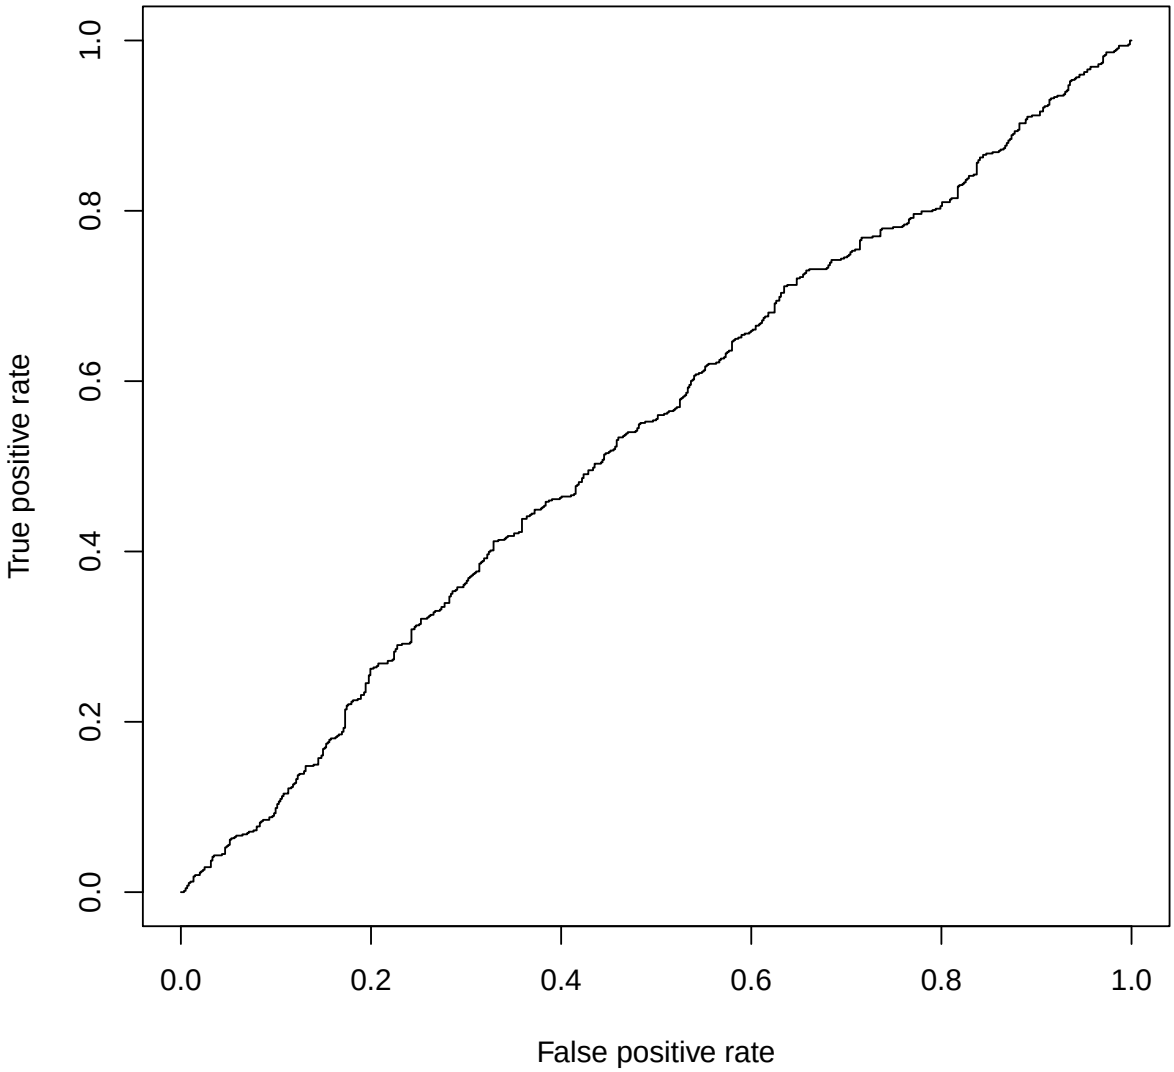


```
AUC(predict(gl), Smarket$Direction)

## [1] 0.5387341

xyplot(Direction ~ predict(gl, type = "response"),
    data = Smarket, groups = Direction, par.settings = simpleTheme(pch = 1:2))
```

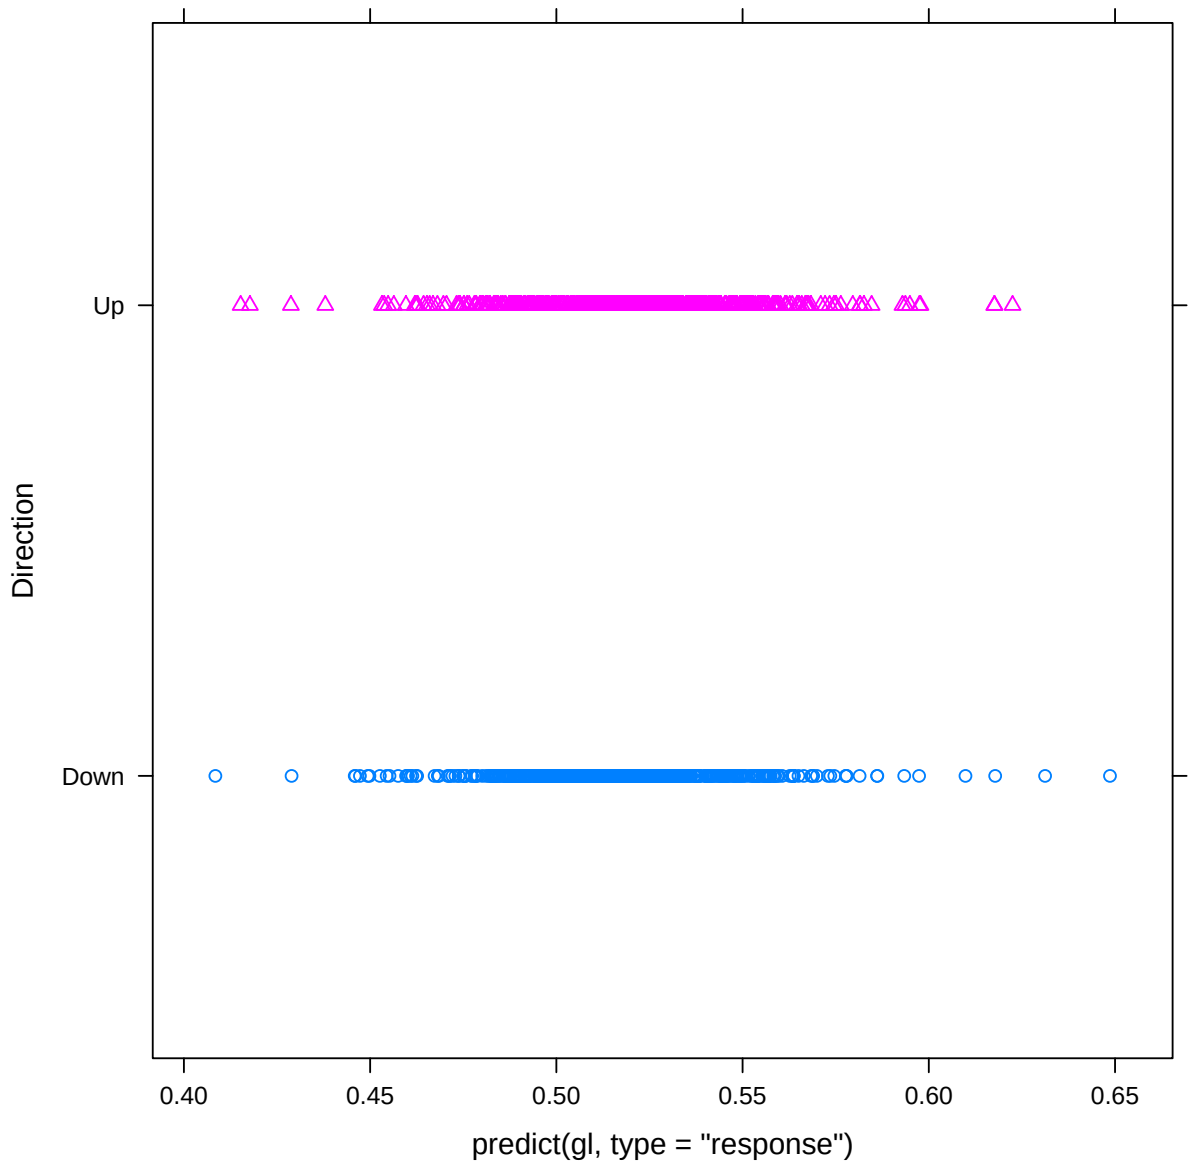


```
bwplot(Direction ~ predict(gl, type = "response"),
    data = Smarket)
```

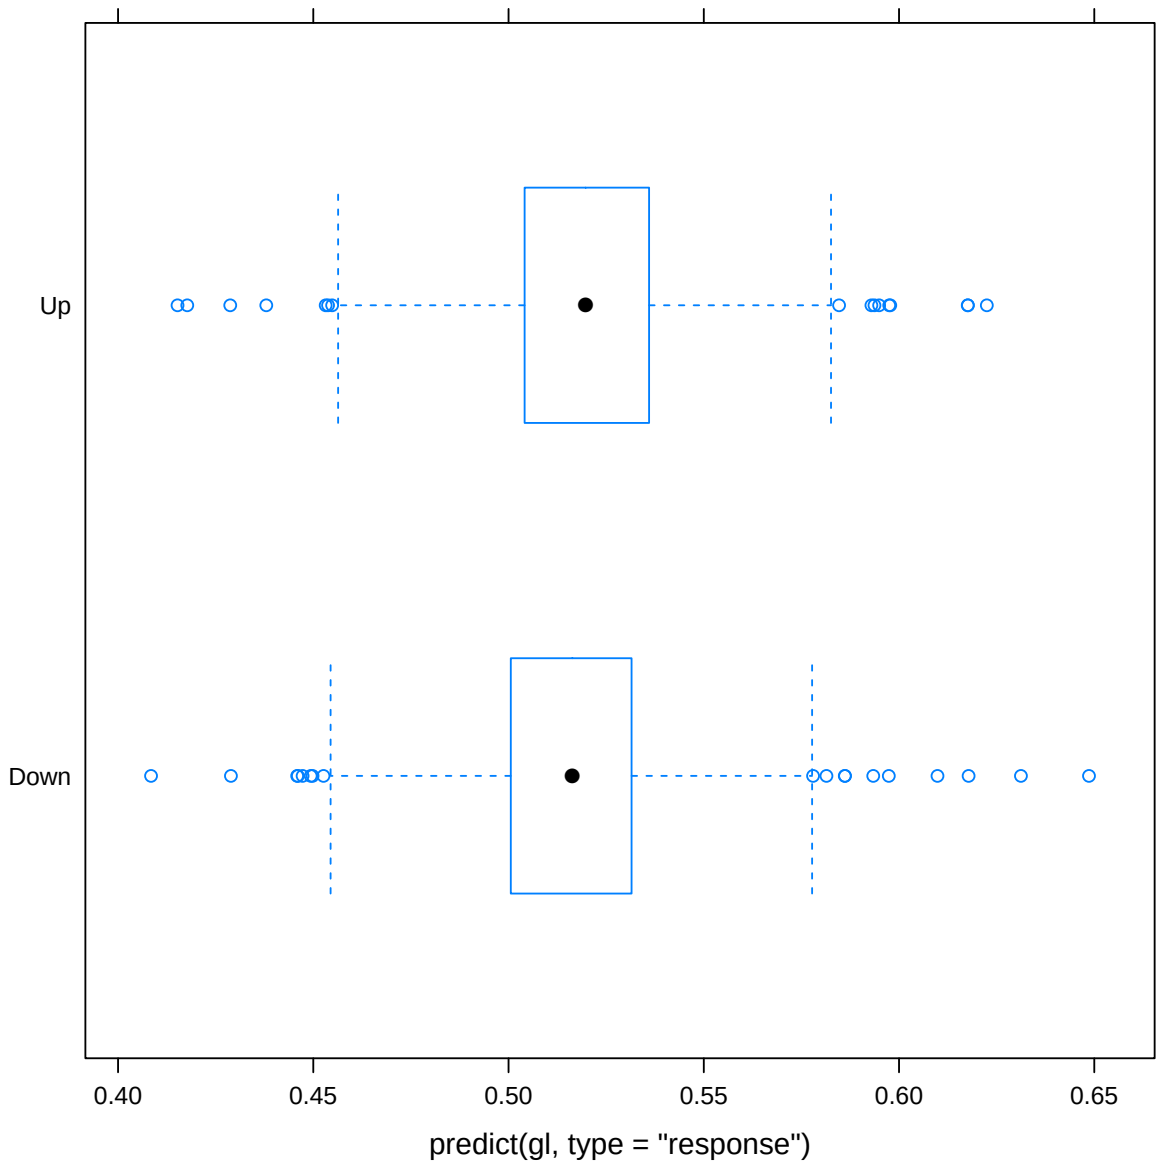


```
bwplot(Direction ~ predict(gl, type = "response"),
    data = Smarket, panel = panel.violin)
```

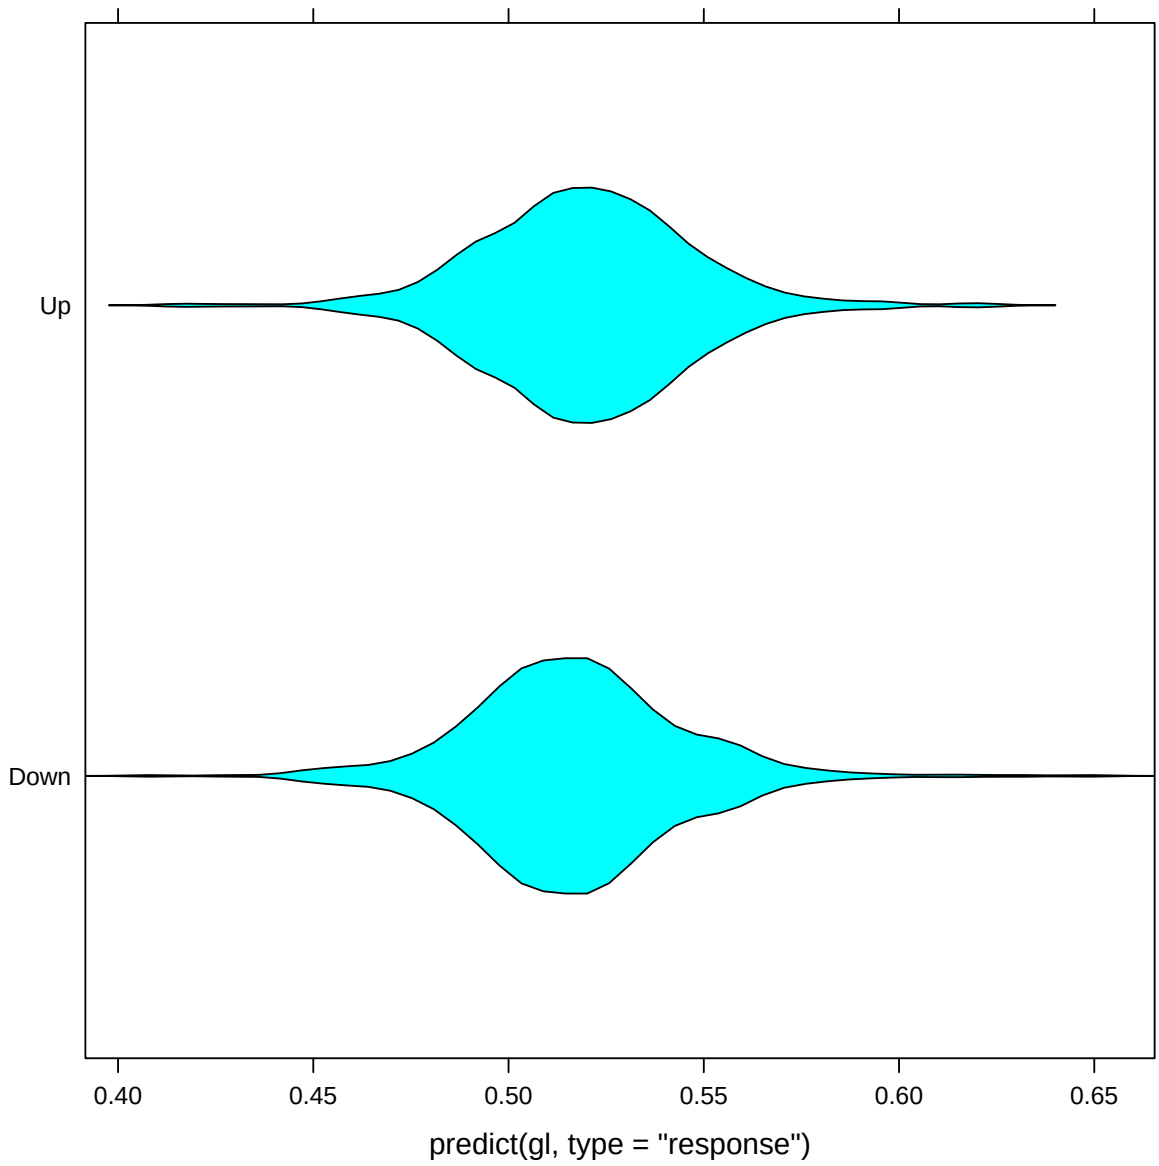


```
gl <- glm(Direction ~ Volume + Lag1 + Lag2,
    data = Smarket, family = binomial(link = "logit"))
summary(gl)

##
## Call:
## glm(formula = Direction ~ Volume + Lag1 + Lag2, family = binomial(link = "logit"
##     data = Smarket)
##
## Deviance Residuals:
##    Min      1Q  Median      3Q     Max
## -1.452  -1.203   1.068   1.146   1.331
##
## Coefficients:
##             Estimate Std. Error z value Pr(>|z|)
```

```
## (Intercept) -0.12058    0.24018  -0.502    0.616
## Volume       0.13184    0.15799   0.835    0.404
## Lag1        -0.07326    0.05017  -1.460    0.144
## Lag2        -0.04279    0.05006  -0.855    0.393
##
## (Dispersion parameter for binomial family taken to be 1)
##
##     Null deviance: 1731.2  on 1249  degrees of freedom
## Residual deviance: 1727.7  on 1246  degrees of freedom
## AIC: 1735.7
##
## Number of Fisher Scoring iterations: 3

roc <- ROC(predict(gl), Smarket$Direction)
plot(roc)
```

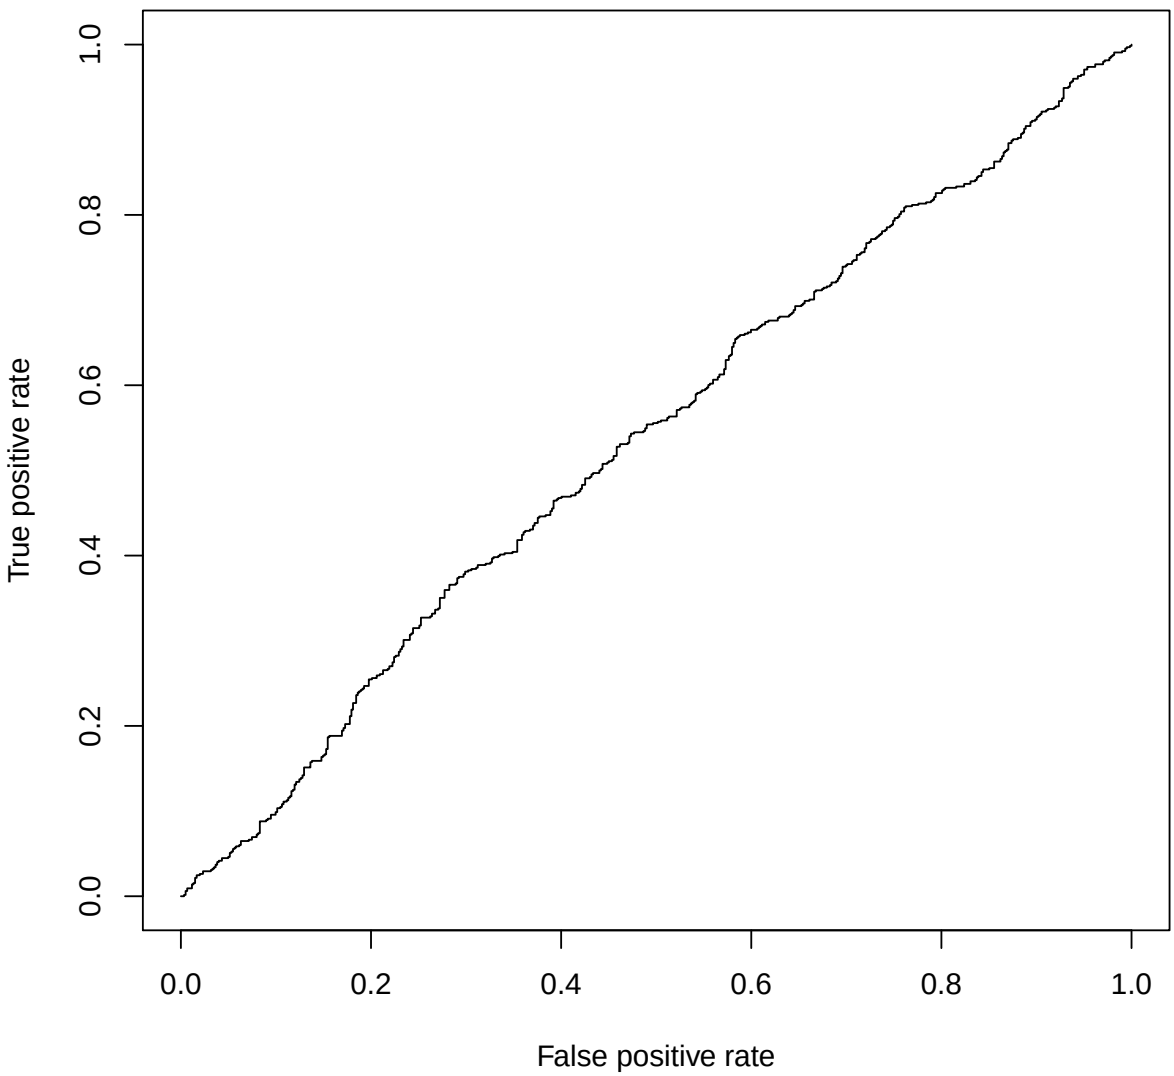

```r
AUC(predict(gl), Smarket$Direction)

## [1] 0.537096

gl <- glm(Direction ~ poly(Volume, Lag1,
    Lag2, degree = 2), data = Smarket, family = binomial(link = "logit"))
roc <- ROC(predict(gl), Smarket$Direction)
plot(roc)
```

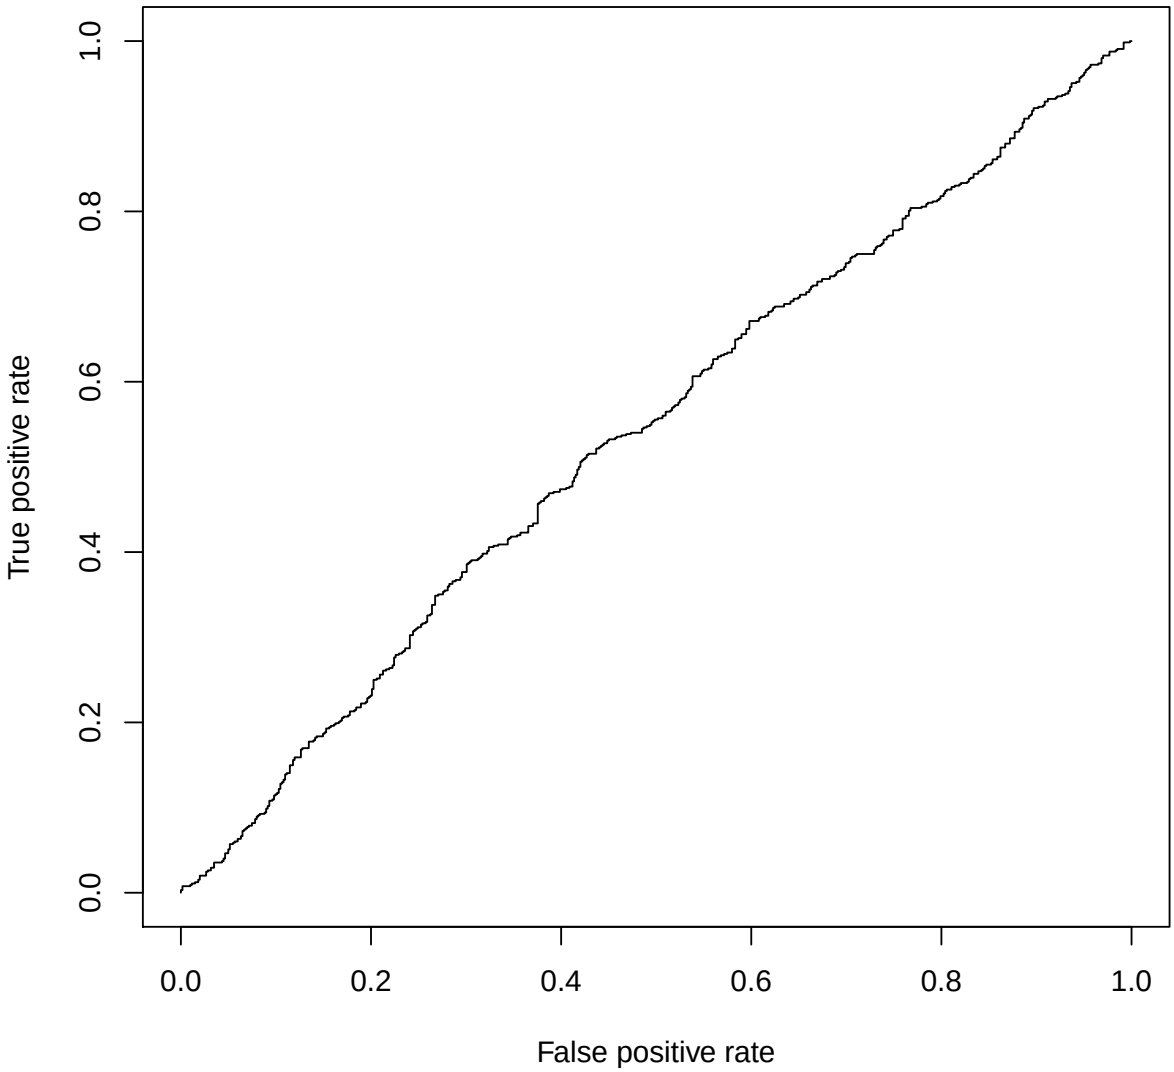


```r
AUC(predict(gl), Smarket$Direction)

## [1] 0.5401183

library(e1071)
tn.glm <- tune(glm, Direction ~ poly(Volume,
```

```r
    Lag1, Lag2, degree = 2), data = Smarket,
    family = binomial(link = "logit"), predict.func = simple.predict.glm,
    tunecontrol = tune.control(cross = 100))
tn.mglm <- tune(glm, Direction ~ poly(Volume,
    Lag1, Lag2, degree = 2), data = Smarket,
    family = binomial(link = "logit"), predict.func = function(...) my.predict.glm(
        measure = "err"), tunecontrol = tune.control(cross = 100))
tn.glm

##
## Error estimation of 'glm' using 100-fold cross validation: 0.5007692

tn.mglm

##
## Error estimation of 'glm' using 100-fold cross validation: 0.4994231

tn.mglm$performances$dispersion

## [1] 0.1389086

tn.qda <- tune(qda, Direction ~ Volume +
    Lag1 + Lag2, data = Smarket, predict.func = simple.predict.da,
    tunecontrol = tune.control(cross = 100))
tn.qda

##
## Error estimation of 'qda' using 100-fold cross validation: 0.5196154

Smarket.train <- subset(Smarket, Year <=
    2004)
Smarket.test <- subset(Smarket, Year > 2004)
qd <- qda(Direction ~ Lag1 + Lag2, data = Smarket.train)
cm.train <- table(actual = Smarket.train$Direction,
    predicted = predict(qd, Smarket.train)$class)
cm.test <- table(actual = Smarket.test$Direction,
    predicted = predict(qd, Smarket.test)$class)
chisq.test(cm.test)

##
##  Pearson's Chi-squared test with Yates' continuity
##  correction
##
## data:  cm.test
## X-squared = 5.6585, df = 1, p-value = 0.01737
```

5.4 banknote

```r
source("class.R")
banknote <- read.csv("banknote/data_banknote_authentication.txt",
    header = FALSE, comment.char = "#")
colnames(banknote) <- c("variance", "skewness",
    "curtosis", "entropy", "class")
banknote$class <- factor(banknote$class,
    labels = c("genuine", "forged"))
summary(banknote)

##     variance          skewness          curtosis
##  Min.   :-7.0421   Min.   :-13.773   Min.   :-5.2861
##  1st Qu.:-1.7730   1st Qu.: -1.708   1st Qu.:-1.5750
##  Median : 0.4962   Median :  2.320   Median : 0.6166
##  Mean   : 0.4337   Mean   :  1.922   Mean   : 1.3976
##  3rd Qu.: 2.8215   3rd Qu.:  6.815   3rd Qu.: 3.1793
##  Max.   : 6.8248   Max.   : 12.952   Max.   :17.9274
##     entropy            class
##  Min.   :-8.5482   genuine:762
##  1st Qu.:-2.4135   forged :610
##  Median :-0.5867
##  Mean   :-1.1917
##  3rd Qu.: 0.3948
##  Max.   : 2.4495

nb <- naiveBayes(class ~ ., data = banknote)
ld <- lda(class ~ ., data = banknote)
qd <- qda(class ~ ., data = banknote)
gl <- glm(class ~ ., data = banknote, family = binomial(link = "logit"))

## Warning: glm.fit: fitted probabilities numerically 0 or 1 occurred

table(predicted = predict(nb, banknote),
    actual = banknote$class)

##          actual
## predicted genuine forged
##   genuine     671    127
##   forged       91    483

tn <- tune(naiveBayes, class ~ ., data = banknote)
tn

##
## Error estimation of 'naiveBayes' using 10-fold cross validation: 0.1581561

tn$performances$dispersion

## [1] 0.02276673
```

```
tn.glm <- tune(glm, class ~ ., data = banknote,
    family = binomial(link = "logit"), predict.func = simple.predict.glm)

## Warning: glm.fit: fitted probabilities numerically 0 or 1 occurred
## Warning: glm.fit: fitted probabilities numerically 0 or 1 occurred
## Warning: glm.fit: fitted probabilities numerically 0 or 1 occurred
## Warning: glm.fit: fitted probabilities numerically 0 or 1 occurred
## Warning: glm.fit: fitted probabilities numerically 0 or 1 occurred
## Warning: glm.fit: fitted probabilities numerically 0 or 1 occurred
## Warning: glm.fit: fitted probabilities numerically 0 or 1 occurred
## Warning: glm.fit: fitted probabilities numerically 0 or 1 occurred
## Warning: glm.fit: fitted probabilities numerically 0 or 1 occurred
## Warning: glm.fit: fitted probabilities numerically 0 or 1 occurred
## Warning: glm.fit: fitted probabilities numerically 0 or 1 occurred

tn.lda <- tune(lda, class ~ ., data = banknote,
    predict.func = simple.predict.da)
tn.qda <- tune(qda, class ~ ., data = banknote,
    predict.func = simple.predict.da)
tn.nb <- tune(naiveBayes, class ~ ., data = banknote)
tn.mglm <- tune(glm, class ~ ., data = banknote,
    family = binomial(link = "logit"), predict.func = function(...) my.predict.glm(
        measure = "err"))

## Warning: glm.fit: fitted probabilities numerically 0 or 1 occurred
## Warning: glm.fit: fitted probabilities numerically 0 or 1 occurred
## Warning: glm.fit: fitted probabilities numerically 0 or 1 occurred
## Warning: glm.fit: fitted probabilities numerically 0 or 1 occurred
## Warning: glm.fit: fitted probabilities numerically 0 or 1 occurred
## Warning: glm.fit: fitted probabilities numerically 0 or 1 occurred
## Warning: glm.fit: fitted probabilities numerically 0 or 1 occurred
## Warning: glm.fit: fitted probabilities numerically 0 or 1 occurred
## Warning: glm.fit: fitted probabilities numerically 0 or 1 occurred
## Warning: glm.fit: fitted probabilities numerically 0 or 1 occurred
## Warning: glm.fit: fitted probabilities numerically 0 or 1 occurred

tn.mlda <- tune(my.lda, class ~ ., data = banknote,
    predict.func = function(...) my.predict.da(...,
        measure = "err"))
tn.mqda <- tune(my.qda, class ~ ., data = banknote,
    predict.func = function(...) my.predict.da(...,
        measure = "err"), tunecontrol = tune.control(cross = 100))
tn.lda

##
## Error estimation of 'lda' using 10-fold cross validation: 0.02552629

tn.qda
```

```
##
## Error estimation of 'qda' using 10-fold cross validation: 0.01676716
```

```
tn.glm
```

```
##
## Error estimation of 'glm' using 10-fold cross validation: 0.01092246
```

```
tn.nb
```

```
##
## Error estimation of 'naiveBayes' using 10-fold cross validation: 0.1588649
```

```
tn.mlda
```

```
##
## Error estimation of 'my.lda' using 10-fold cross validation: 0.01166296
```

```
tn.mqda
```

```
##
## Error estimation of 'my.qda' using 100-fold cross validation: 0.0007142857
```

```
summary(tn.mglm$best.model)
```

```
##
## Call:
## best.tune(method = glm, train.x = class ~ ., data = banknote,
##     predict.func = function(...) my.predict.glm(..., measure = "err"),
##     family = binomial(link = "logit"))
##
## Deviance Residuals:
##      Min        1Q    Median        3Q       Max
## -1.70001   0.00000   0.00000   0.00029   2.24614
##
## Coefficients:
##             Estimate Std. Error z value Pr(>|z|)
## (Intercept)   7.3218     1.5589   4.697 2.64e-06 ***
## variance     -7.8593     1.7383  -4.521 6.15e-06 ***
## skewness     -4.1910     0.9041  -4.635 3.56e-06 ***
## curtosis     -5.2874     1.1612  -4.553 5.28e-06 ***
## entropy      -0.6053     0.3307  -1.830   0.0672 .
## ---
## Signif. codes:
## 0 '***' 0.001 '**' 0.01 '*' 0.05 '.' 0.1 ' ' 1
##
## (Dispersion parameter for binomial family taken to be 1)
##
##     Null deviance: 1885.122  on 1371  degrees of freedom
## Residual deviance:   49.891  on 1367  degrees of freedom
## AIC: 59.891
##
## Number of Fisher Scoring iterations: 12
```

```r
summary(tn.mqda$best.model)

##         Length Class      Mode
## prior    2     -none-     numeric
## counts   2     -none-     numeric
## means    8     -none-     numeric
## scaling 32     -none-     numeric
## ldet     2     -none-     numeric
## lev      2     -none-     character
## N        1     -none-     numeric
## call     6     -none-     call
## terms    3     terms      call
## xlevels  0     -none-     list
## data     5     data.frame list

splom(subset(banknote, select = -class),
    groups = banknote$class)
```

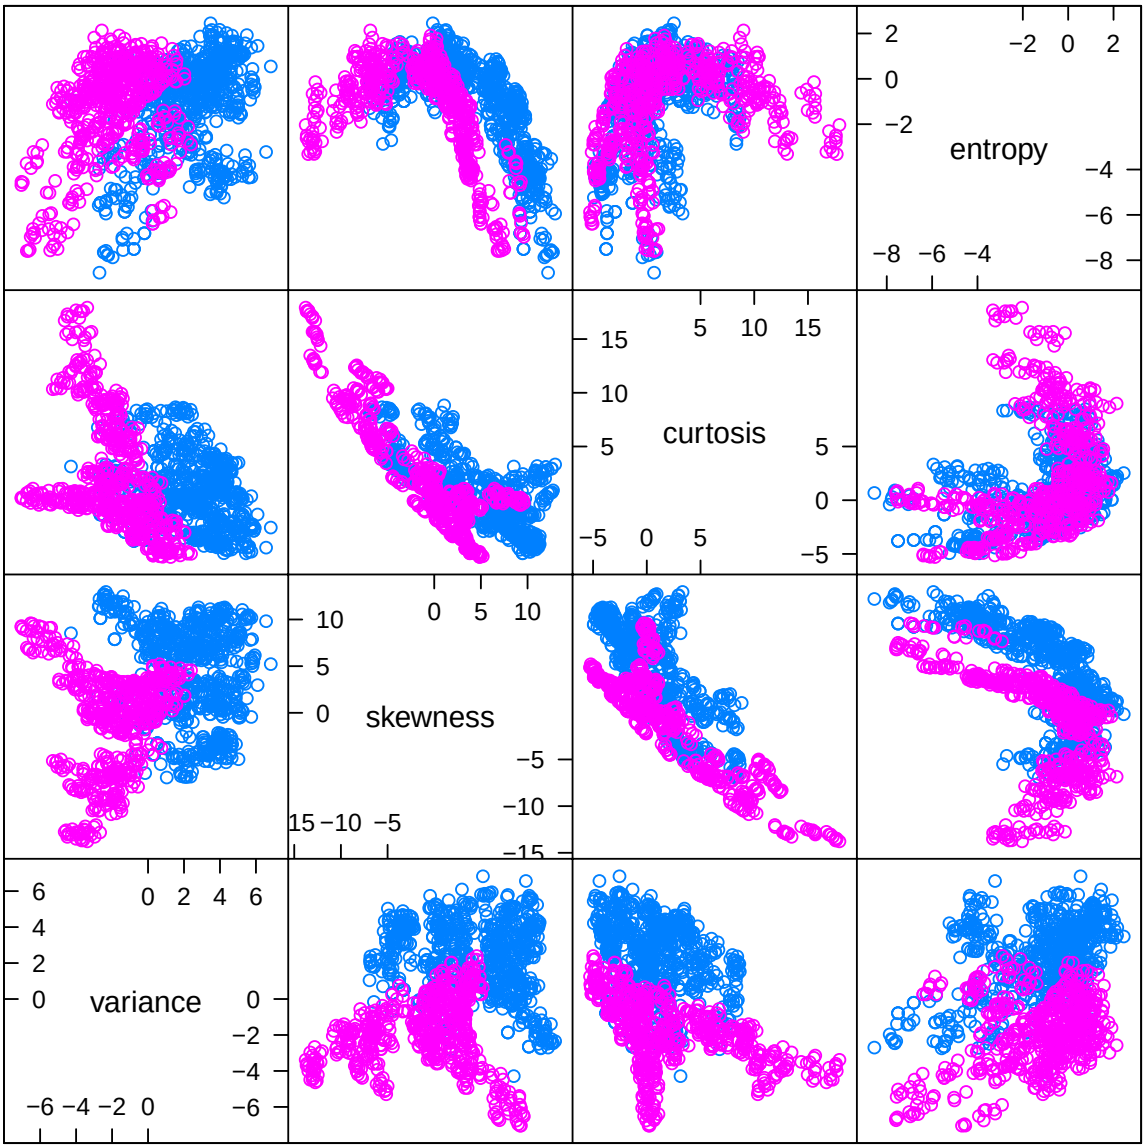

Scatter Plot Matrix

```
splom(cbind(subset(banknote, select = -class),
    glm = predict(tn.mglm$best.model), lda = as.matrix(subset(banknote,
        select = -class)) %*% tn.mlda$best.model$scaling),
    groups = banknote$class)
```

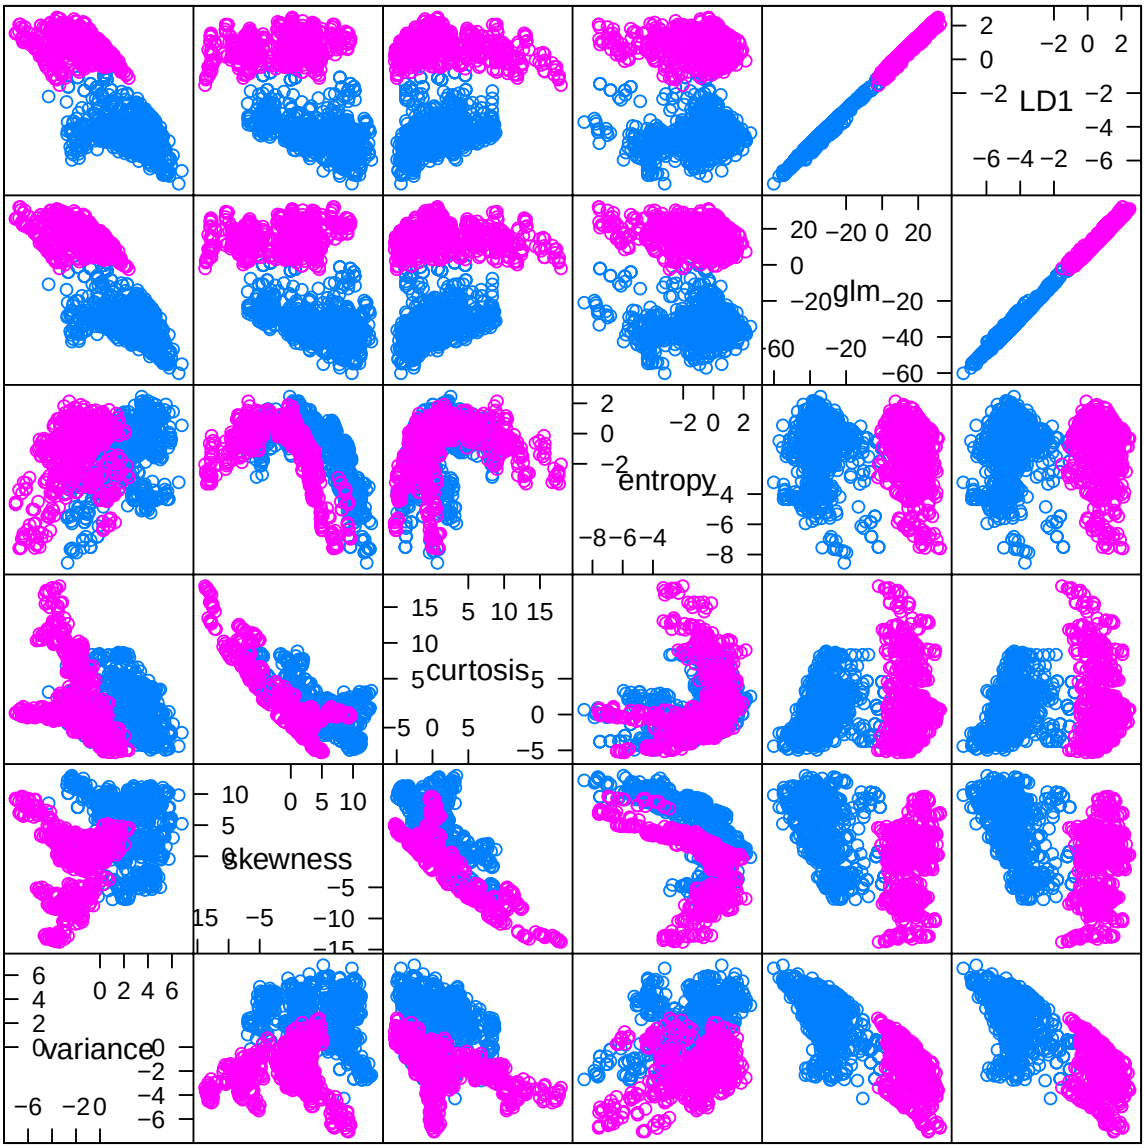

Scatter Plot Matrix

```
densityplot(~predict(tn.glm$best.model),
    groups = banknote$class)
```

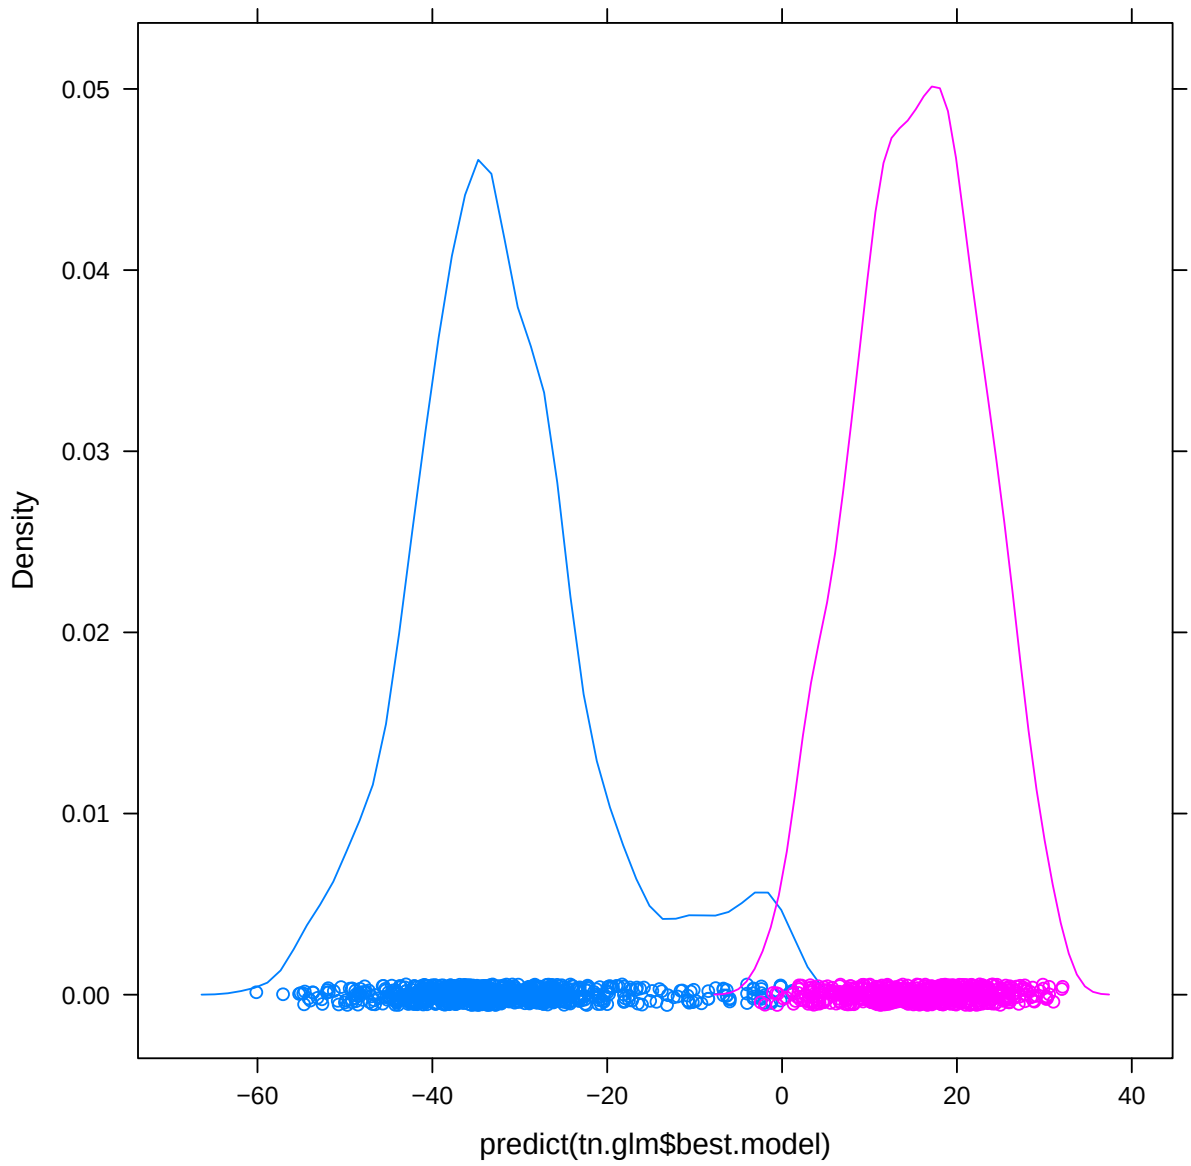


```
train <- sample(nrow(banknote), size = 0.66 *
    nrow(banknote))
gl <- glm(class ~ ., data = banknote, subset = train,
    family = binomial)

## Warning: glm.fit: fitted probabilities numerically 0 or 1 occurred

roc <- ROC(predict(gl, banknote[-train, ],
    type = "response"), as.numeric(banknote[-train,
    ]$class))
plot(roc)
```

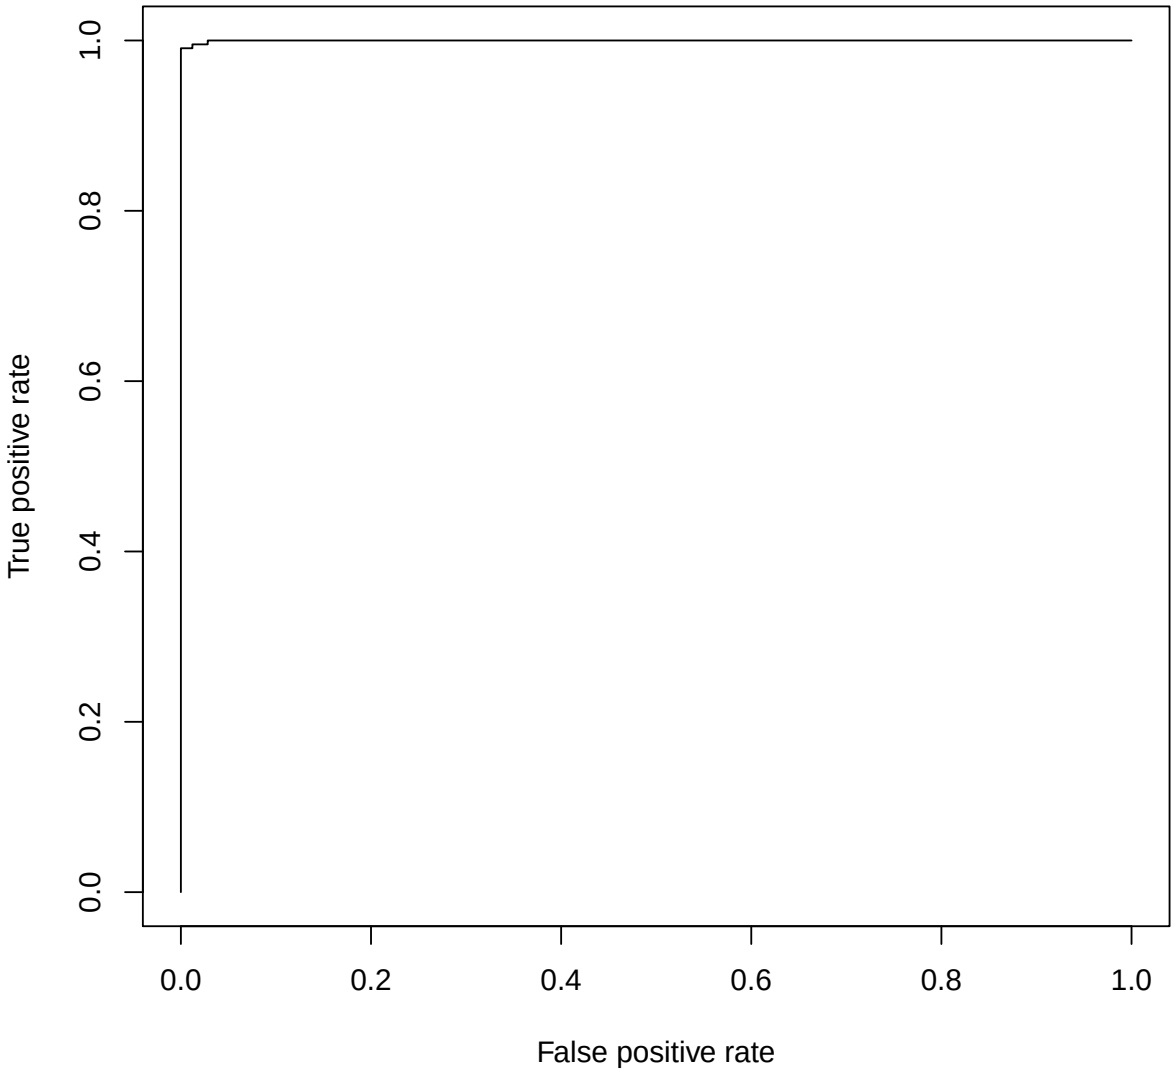

6 Рисование

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)
```

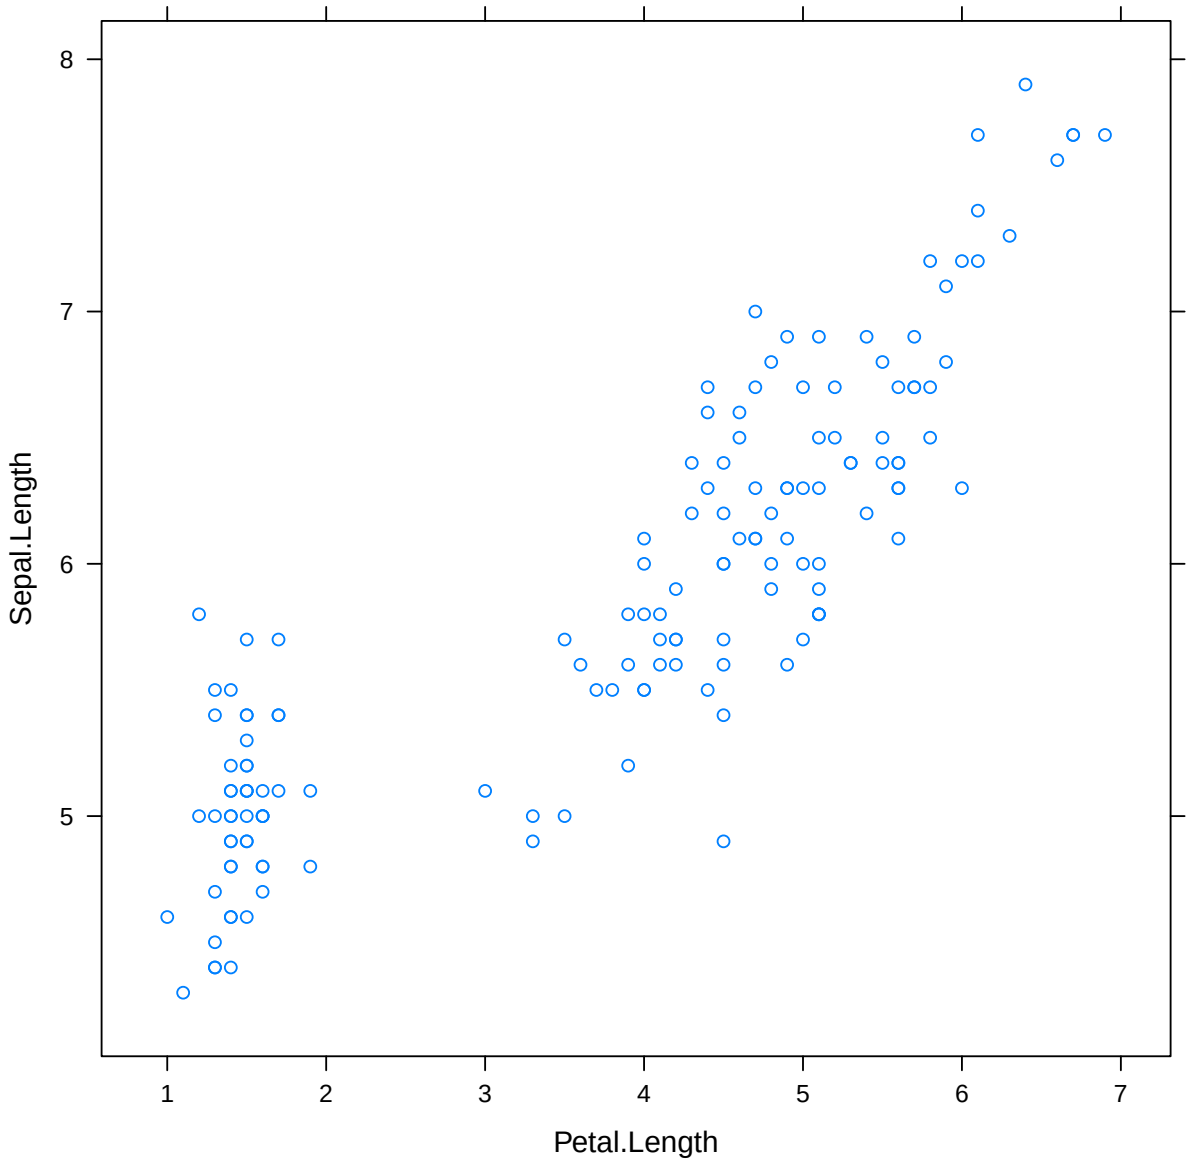

Не очень красиво и малоинформативно. Давайте нарисуем сорта на отдельных графиках:

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

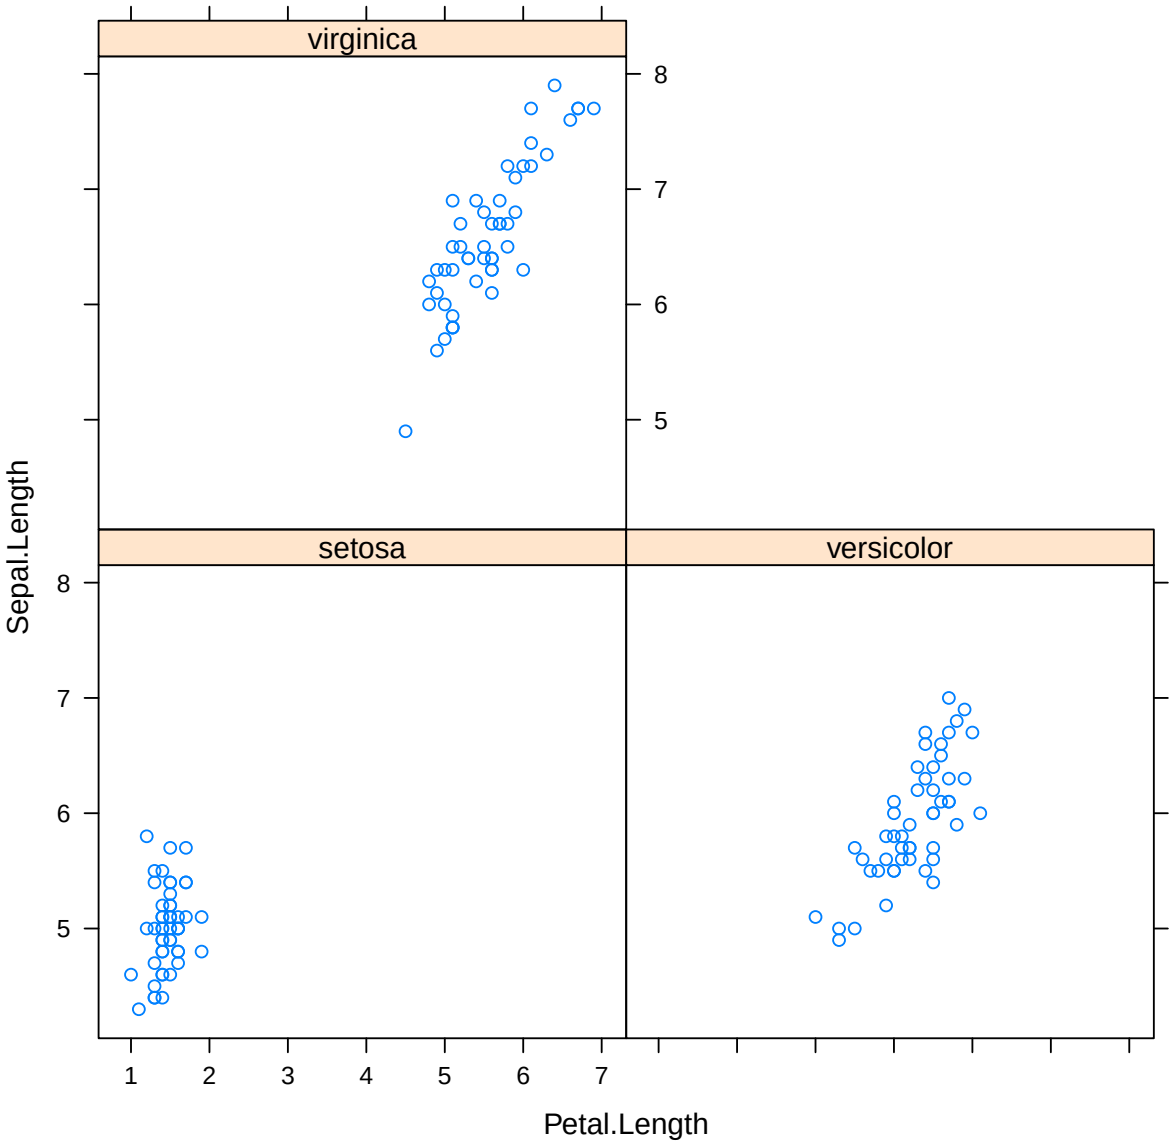

А может лучше все-таки на одном, но разными цветами?.. А еще я хочу сделать точки спрошным и добавить легенду:

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

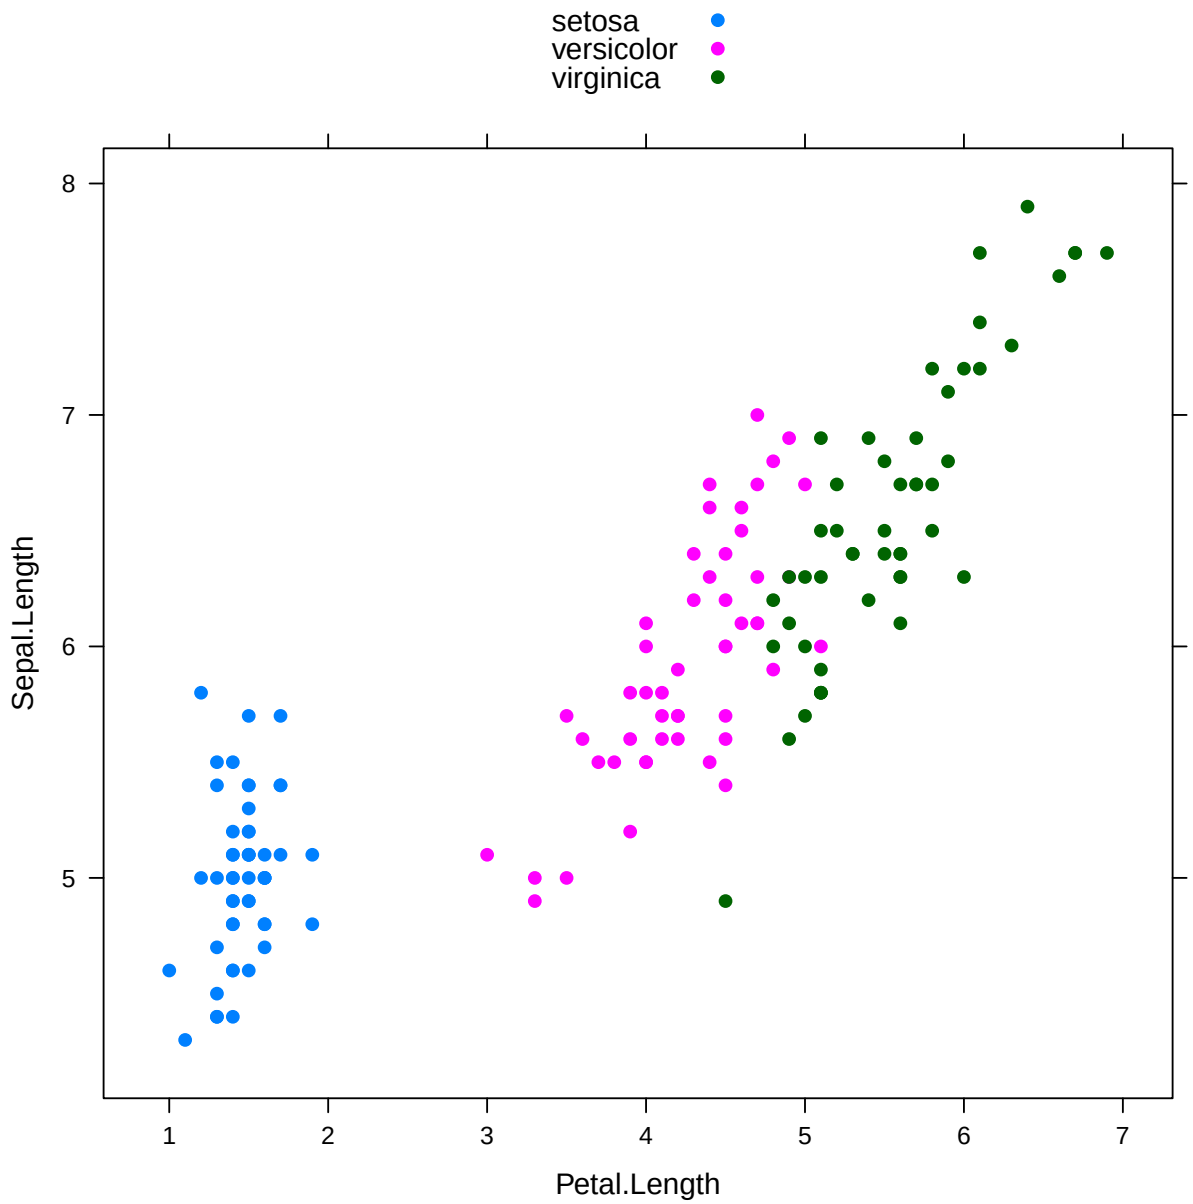


```
library(latticeExtra)
```

```
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")
```

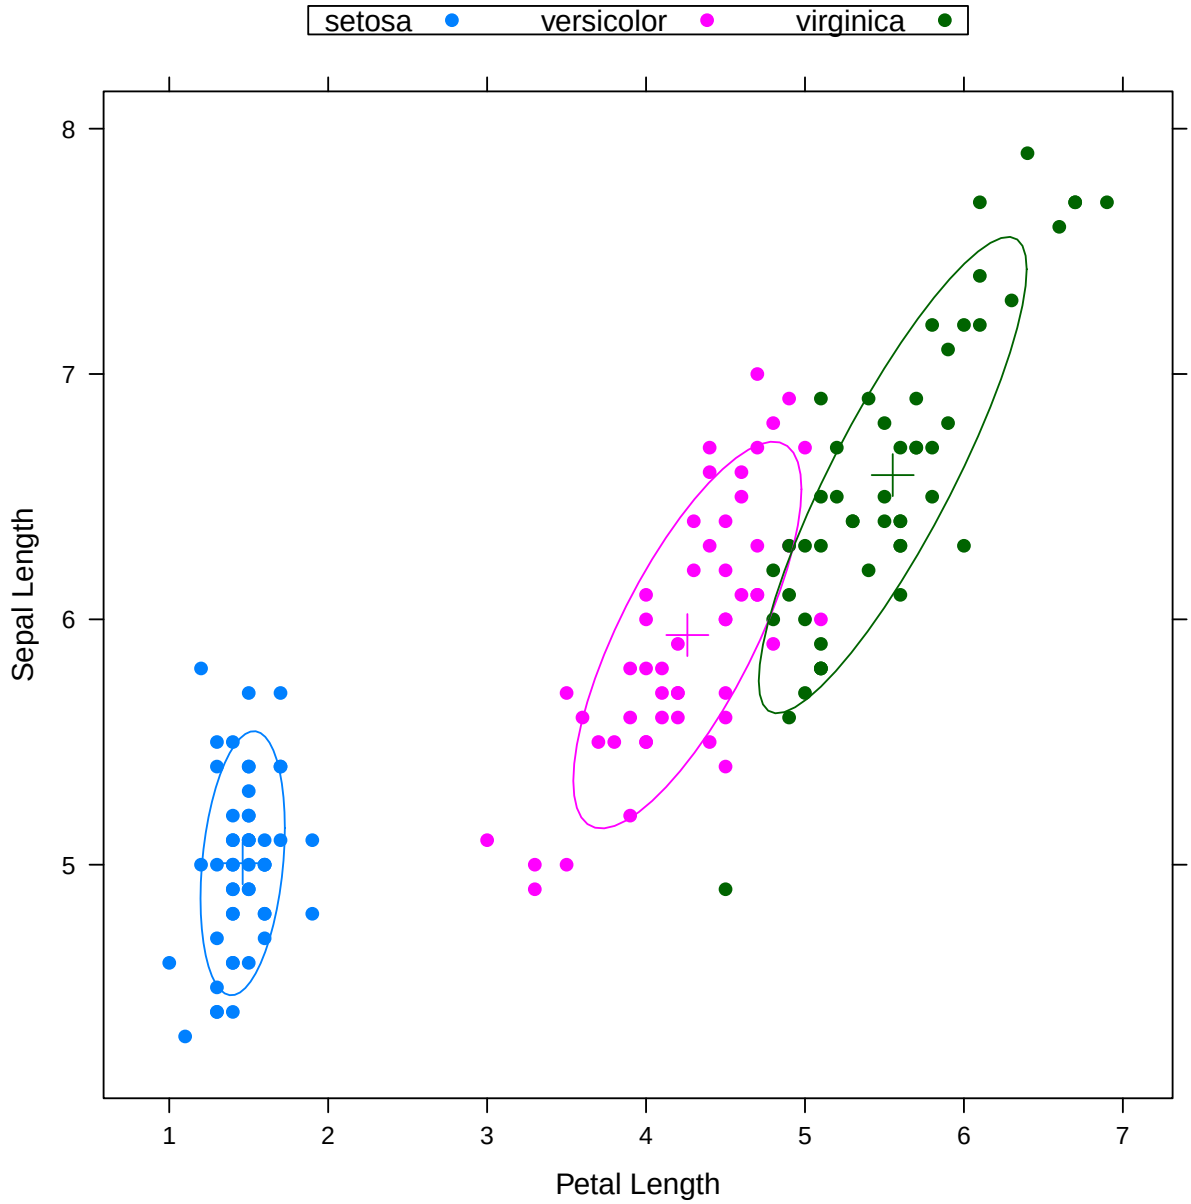

Напоследок приведу пример написания своей панельной функции для `xyplot()`:

```
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 = 2)
```

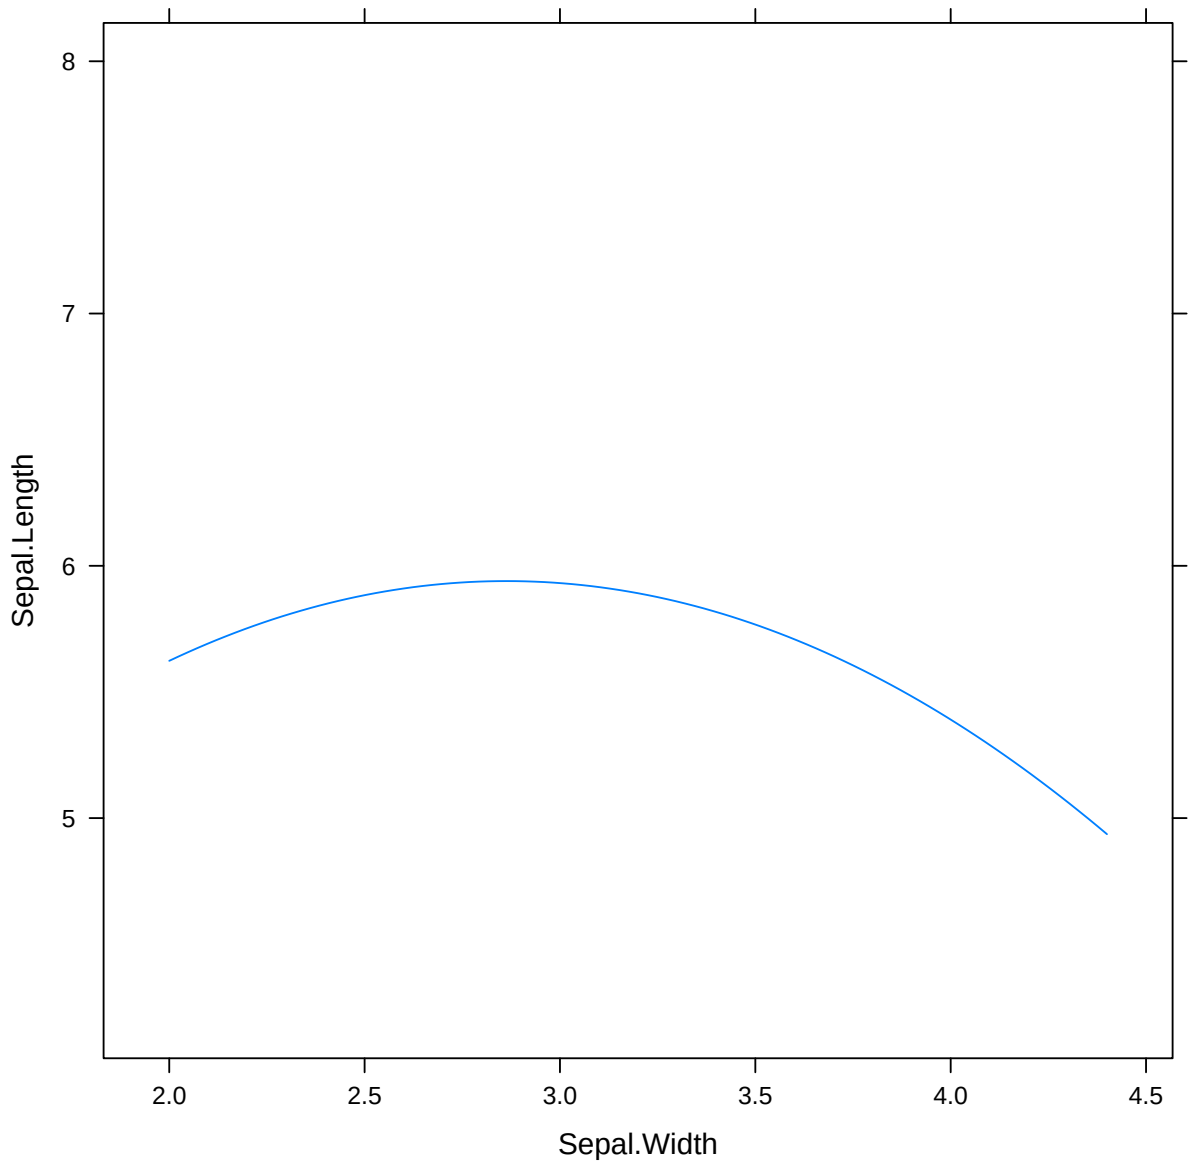


```
xyplot(Sepal.Length ~ Sepal.Width, groups = Species,
    data = iris, panel = panel.lmpolyline,
    degree = 2)
```

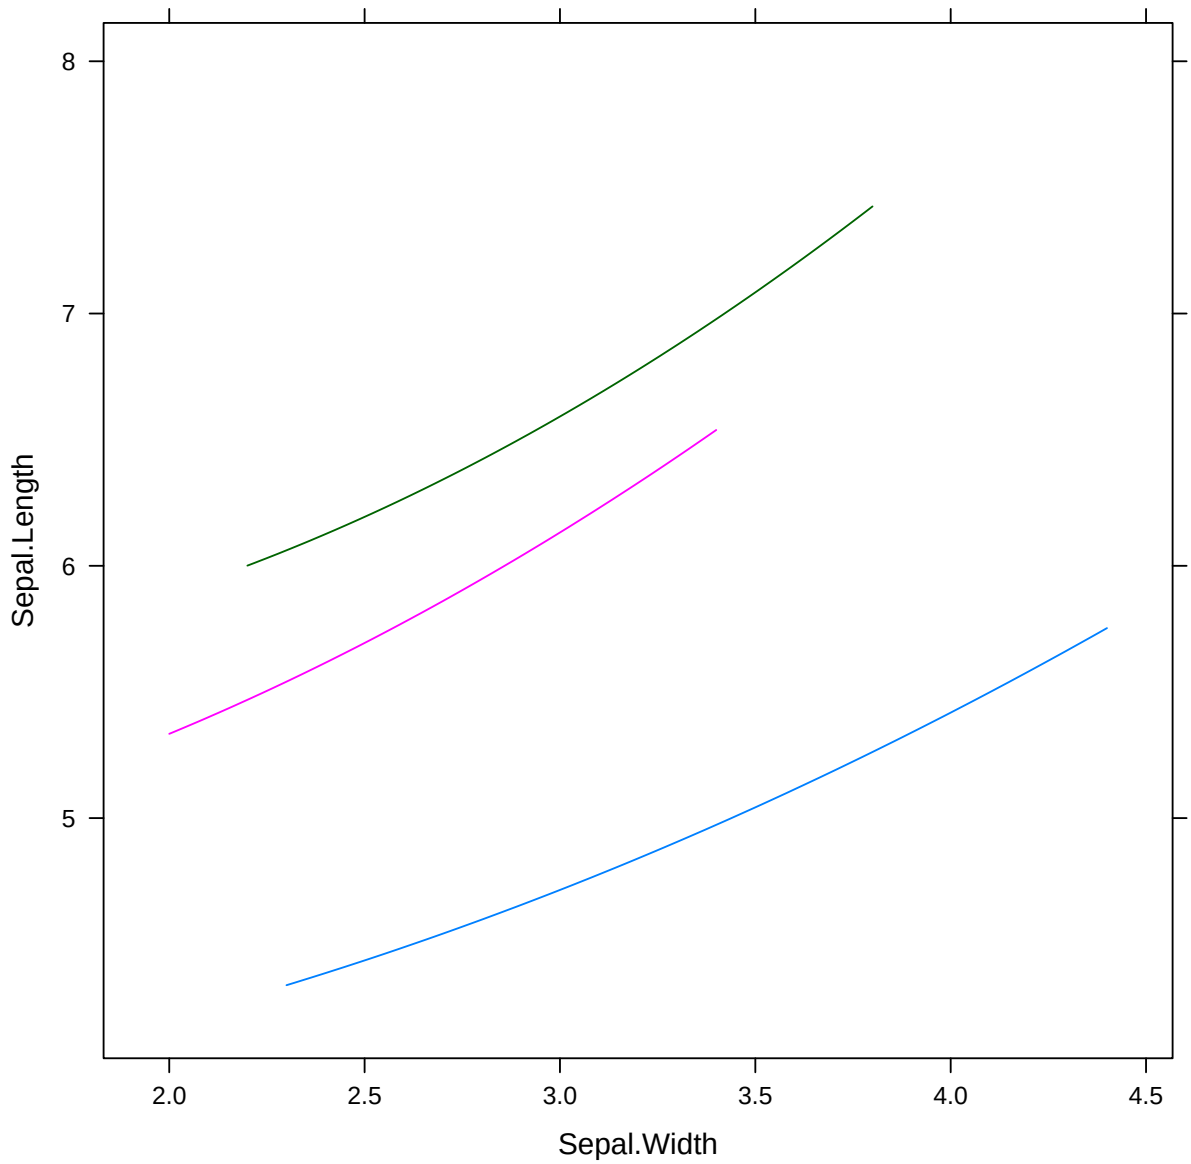


```
xyplot(Sepal.Length ~ Sepal.Width, groups = Species,
    data = iris) + layer_(panel.lmpolyline(...,
    degree = 2))
```

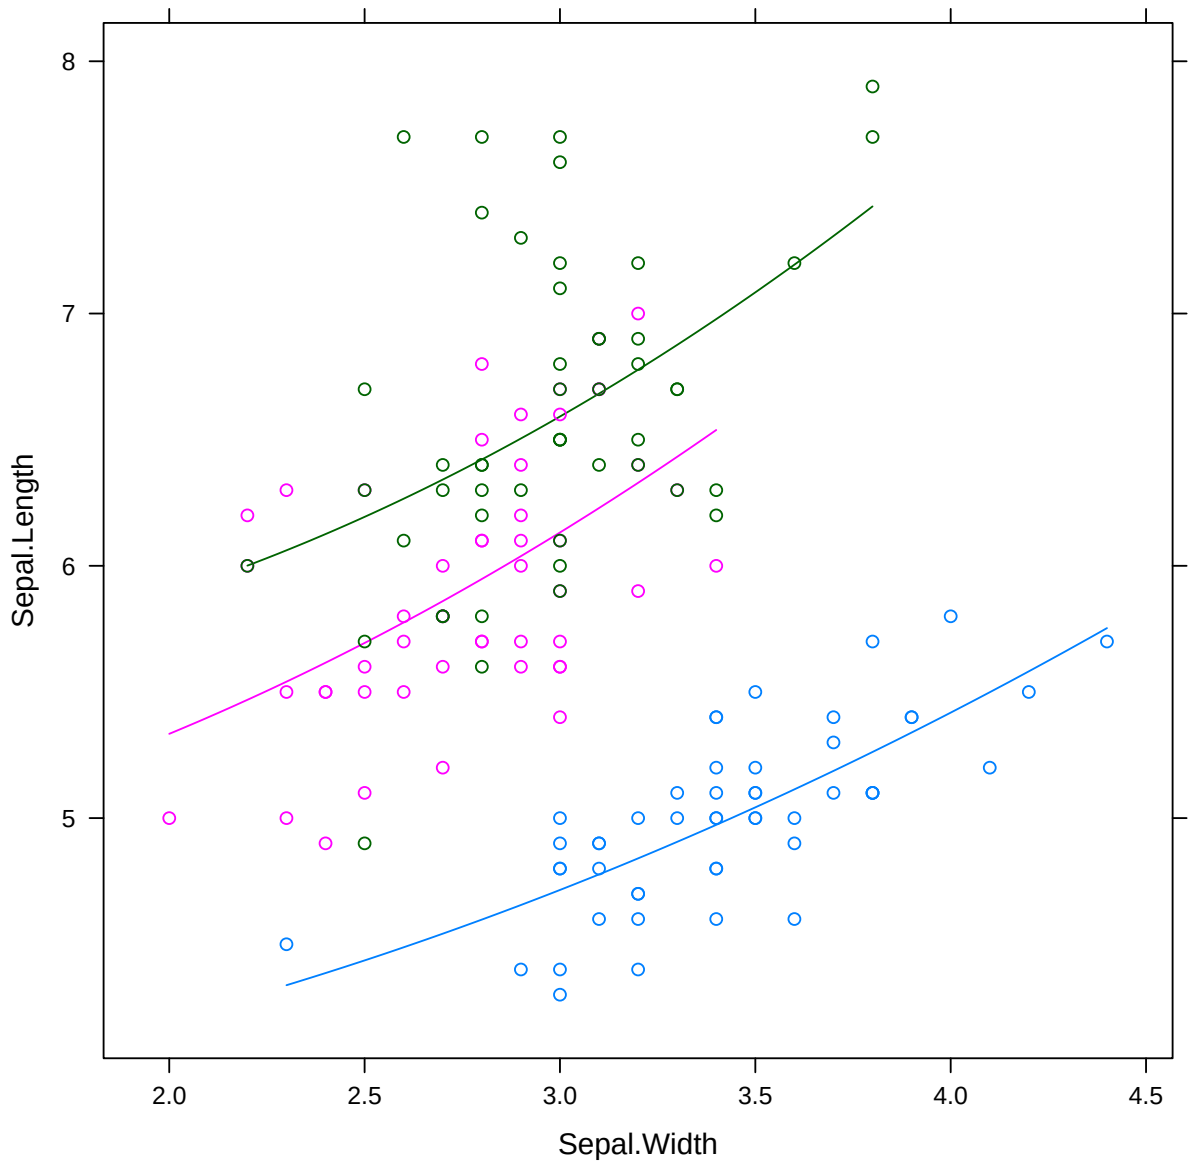


```
panel.kde2d <- function(x, y, groups = NULL,
    subscripts, n = 100, cuts = 5, col.line = par.line$col,
    lty = par.line$lty, lwd = par.line$lwd,
    alpha = par.line$alpha, ..., identifier = "kde2d",
    col) {
    require("MASS")
    x <- as.numeric(x)
    y <- as.numeric(y)
    if (!is.null(groups))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

```r
    } 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.kde2d)
```

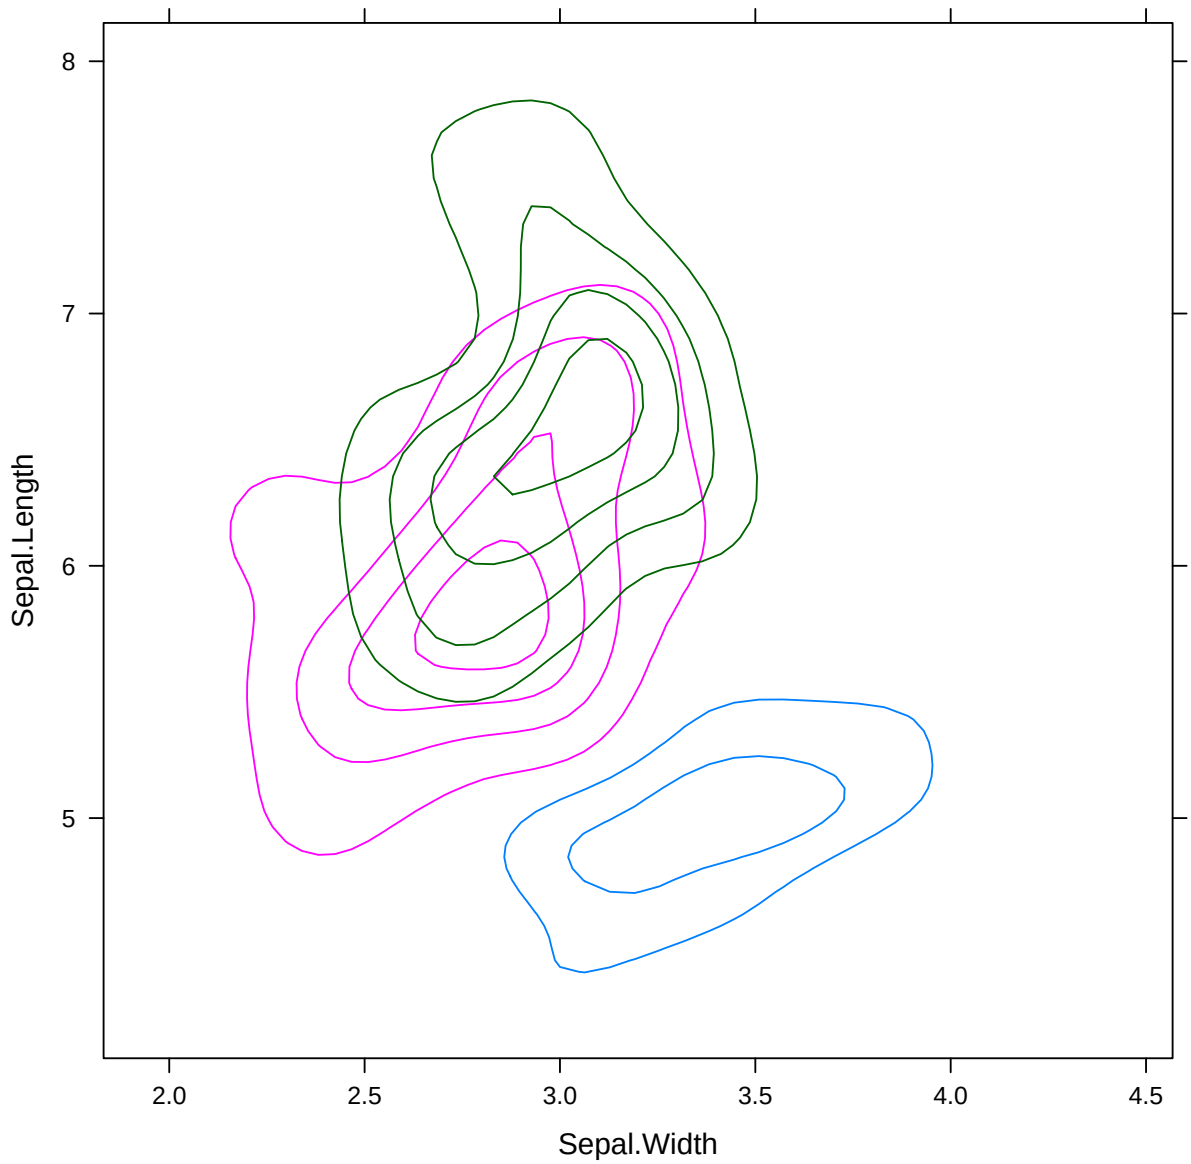


```
xyplot(Sepal.Length ~ Sepal.Width | Species,
    data = iris, groups = Species, par.settings = simpleTheme(pch = 19),
    auto.key = list(columns = 3, lines = TRUE),
    layout = c(3, 1)) + layer_(panel.kde2d(...,
    cuts = 10))
```

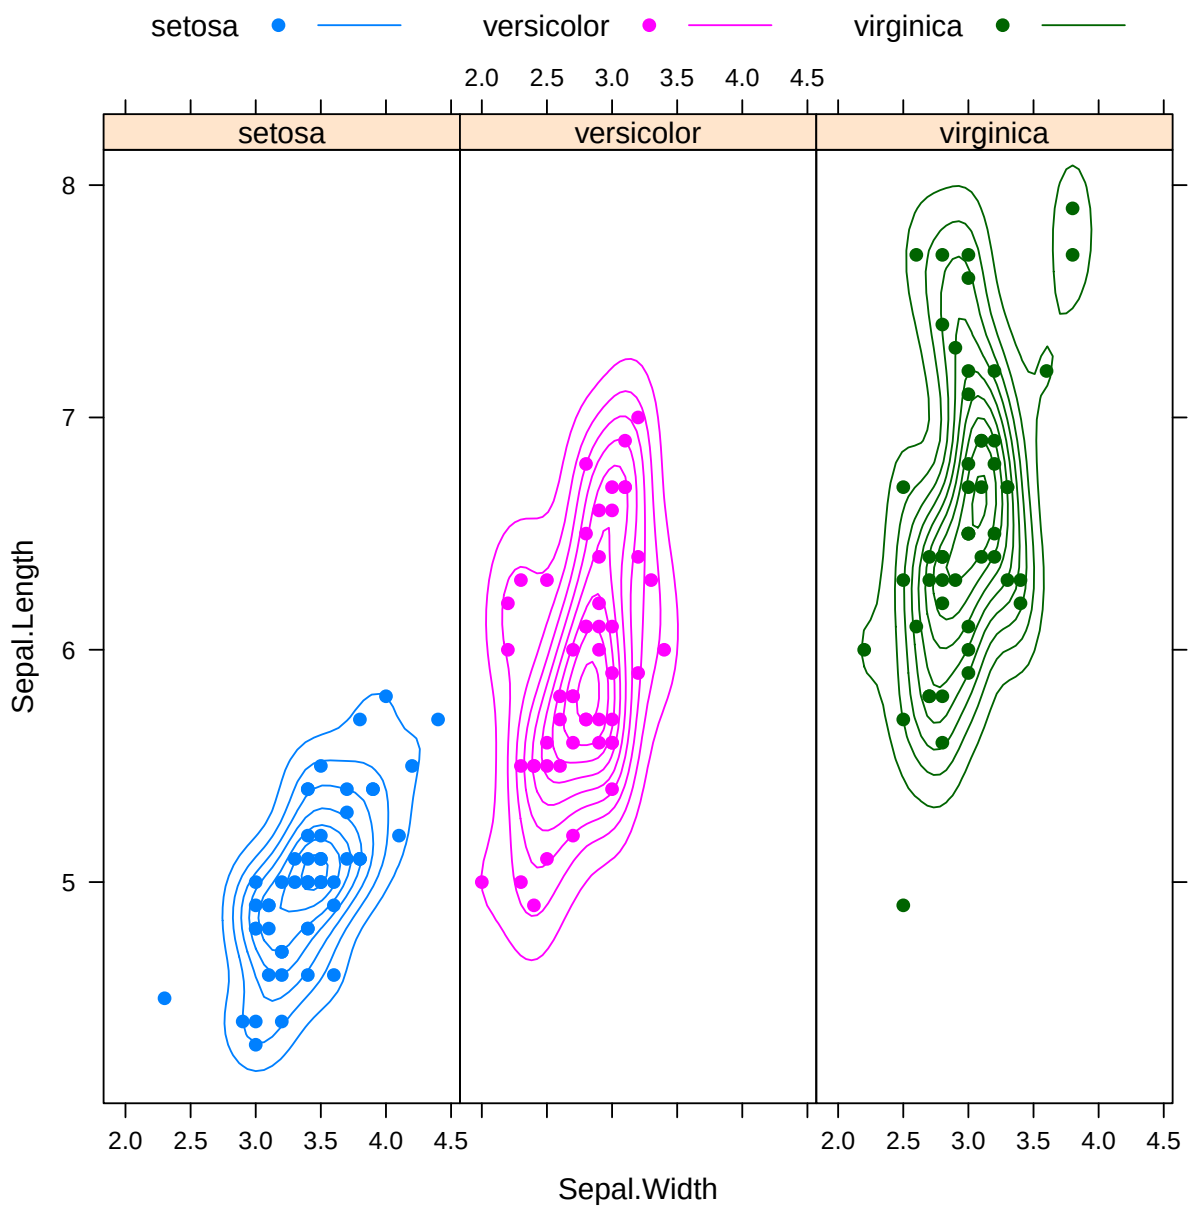


```
xyplot(Sepal.Length ~ Sepal.Width | Species,
    data = iris, groups = Species, par.settings = simpleTheme(pch = 19),
    layout = c(3, 1)) + layer_(panel.kde2d(...,
    cuts = 10))
```

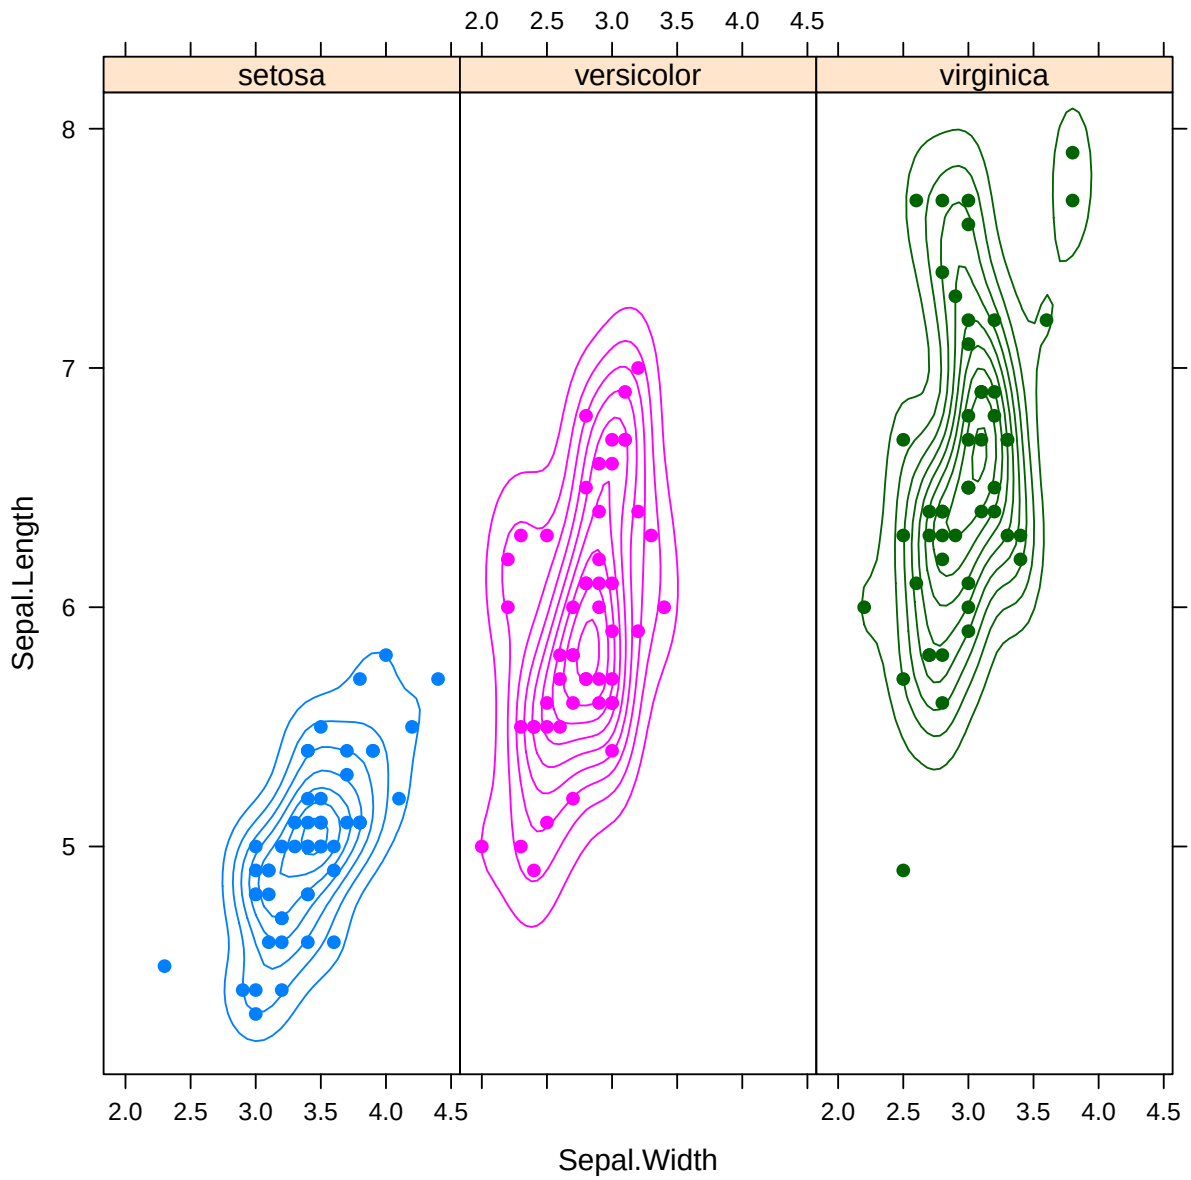


```
xyplot(Sepal.Length ~ Sepal.Width | Species,
    data = iris, groups = Species, par.settings = simpleTheme(pch = 19,
        cex = 0.5, lwd = 1, lty = "dashed"),
    auto.key = list(columns = 3, lines = TRUE),
    layout = c(3, 1)) + layer_(panel.kde2d(...,
    cuts = 10))
```

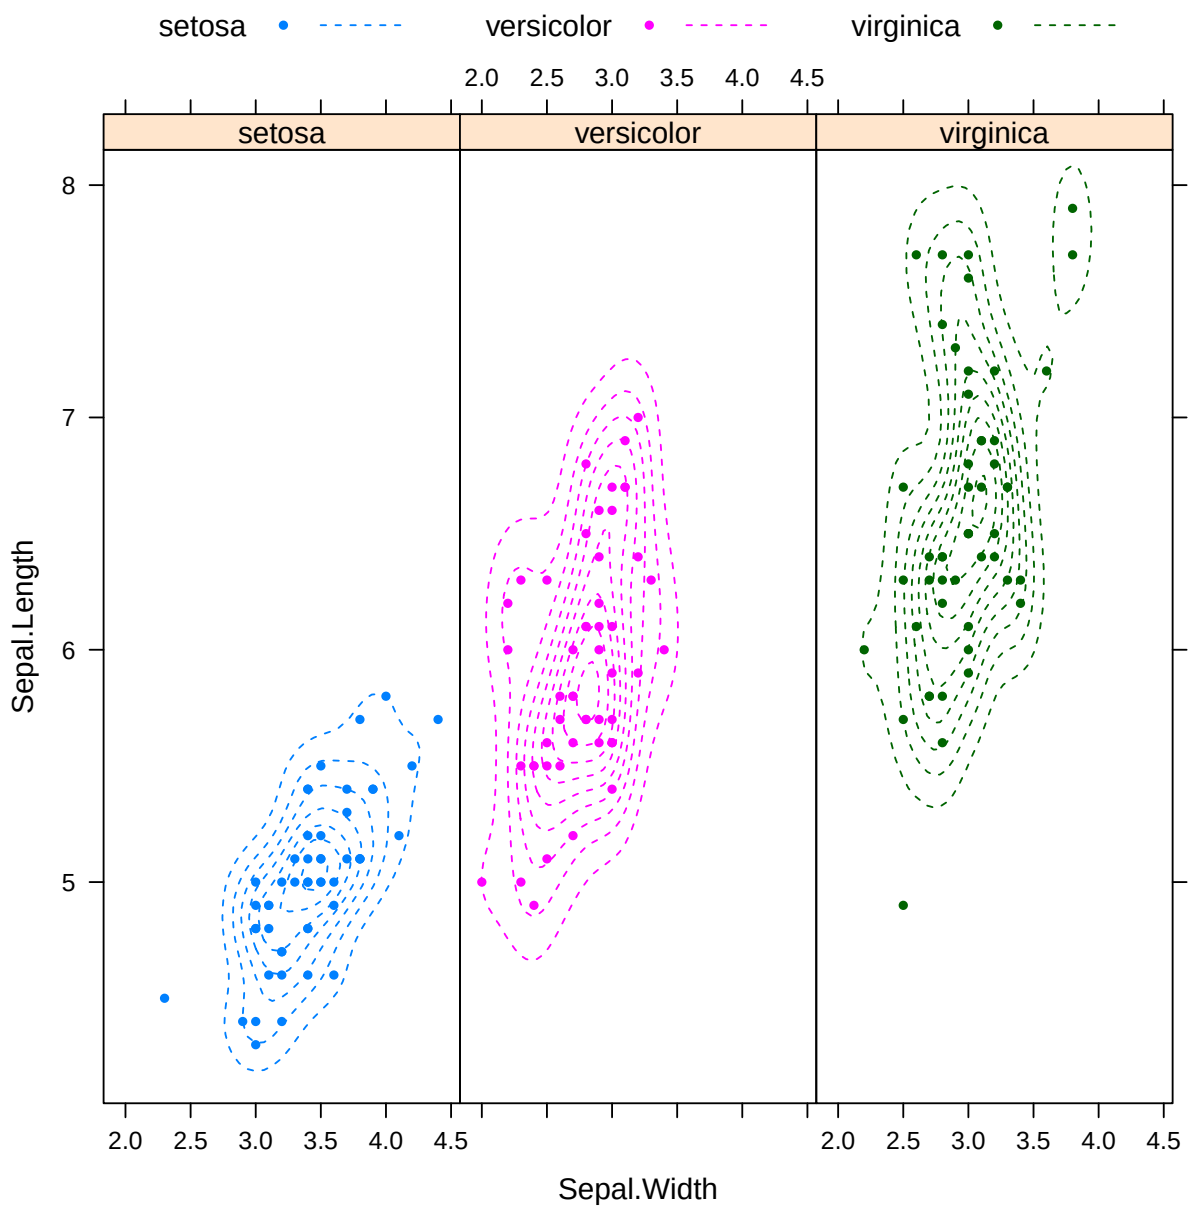

bwplot violinplot densityplot marginal.plot
countourplot
Пример панельной функции для полиномиальной регрессии