

Графическая визуализация в ggplot2

Зачем?

Графический интерфейс базовых графических пакетов R достаточно проста и невзрачна. В пакете `ggplot2` находится ряд графических решений, позволяющих делать более зрелищную визуализацию. `ggvis` позволяет делать интерактивные графики. К сожалению, базовый R не поддерживает такие объекты, поэтому для этого нужна среда визуализации. Одну из таких сред предоставляет RStudio. Вашему вниманию предлагается обзор основных функций `ggplot2`.

Графики qplot

Аналог базовой функции в `ggplot2` носит название `qplot` и имеет параметры `qplot(x, y, data=, color=, shape=, size=, alpha=, geom=, facets=, xlim=, ylim=, xlab=, ylab=, main=, sub=)`.

Эта функция позволяет строить как обычные `scatterplot`, так и гистограммы и `boxplot`.

Аргументы `x,y`, как обычно, это переменные, отложенные по осям. Второй аргумент может быть опущен, если нам нужны линейные данные (например, для гистограммы).

`data` обозначается `data frame`, на основе которого строится график. Указав в его качестве какой-либо `data frame`, мы можем обращаться в остальных переменных к его столбцам без указания. Например `qplot(Petal.Width,Sepal.Width, data = iris)` построит график `iris$Petal.Width` от `iris$Sepal.Width`.

Как и прежде `color` отвечает за цвет линий. В случае заполненных графиков, например, гистограмм, вместо него можно указать `fill =`, что приведет к заполнению соответствующим цветом. Как и прежде, мы можем использовать в качестве `color` массивы, так, например, `qplot(Petal.Width,Sepal.Width, data = iris, color = Species)` построит график с разноветными видами ириса.

`Shape` задает форму точек на графике, `size` — их размер. Скажем, `qplot(Petal.Width,Sepal.Width, data = iris, color = Species, shape = (Petal.Length > 1.6), size = (Sepal.Length > 5))` выделит различными цветами разные виды, а треугольной формой цветки с длинными лепестками, а большим размером цветы с крупной чашечкой.

`alpha` задает прозрачность накладывающихся участков графика.

Параметр `geom` задает формат графика — "point"(обычный точечный график), "line"(линейный),




Рис. 1: График `qplot` для `iris` с различными формами и цветами точек в зависимости от их показателей

"smooth"(сглаженный), "boxplot"(box график), "dotplot" "histogram"(гистограммы с разными формами визуализации), "density"(ядерная оценка плотности на основе выборки), "jitter"(график, в который

добавлен небольшой случайный шум, размывающий облако точек, к примеру, в дискретном случае), "polygon" (заполненный многоугольник).

facets задает дополнительные переменные, итогом qplot будет массив графиков со всеми возможными значениями вспомогательных переменных.

xlab, ylab задают названия осей, xlim, ylim — границы изменения осей, main, sub — титул графика.

Пример 1. Несколько примеров:

qplot(mpg,data=mtcars, geom = "density fill=factor(gear),alpha = 0.5) — плотность параметра mpg (миль на галлон топлива) для разных значений gear.

qplot(mpg,data=mtcars, geom = "histogram fill=gear, color = "black alpha = 0.5,bins = 40) — гистограмма с разбиением на 40 фрагментов, на которой цветом отображено количество данных с каждым значением gear (передача).

qplot(hp, mpg, data=mtcars, color=am, facets=gear~cyl, size=I(3)) — график mpg (миль на галлон топлива) от hp (мощности в лошадиных силах) при каждой паре значений количестве передачи и числа цилиндров, где цвет отражает am — ручная или автоматическая коробка передач.

qplot(gear, mpg, data=mtcars,geom = c("jitter "point")) — график mpg от gear, где к переменным добавлен шум, что позволяет меньше зависеть от дискретизации.




Рис. 2: Плотности mtcars для разных значений переменной gear

Графики ggplot

Другой функцией для задания графика является ggplot. В ggplot задается аргумент data (данные, с которыми мы будем работать) и заданное для построения отображение (его можно создать с помощью функции aes()). Функция aes(x,y) задает формат графика — данные по осям, а также цвет, форму и другие параметры. Кроме того, после ggplot используется функция geom_*(), задающая геометрию графика. Например, geom_point() задаст точечный график.

Пример 2. ggplot(mtcars, aes(mpg,hp,color = gear))+geom_point() создает точечный график hp от mpg с расцветкой, зависящей от gear.

ggplot(mtcars, aes(gear,cyl,fill = gear))+geom_bar(stat = "identity") создает прямоугольный график cyl от gear.

ggplot(mtcars, aes(gear)) + geom_bar(stat="count") создает ряд значений для величины gear.

ggplot(mtcars, aes(mpg,hp,color = gear))+geom_point(size = 3) + geom_line(color = "black linetype

`= "dashed") + expand_limits(y=0)` создает график hp от mpg, `geom_point` задает параметры точек, `geom_line` — параметры линий, `expand_limits` — границы по y (по умолчанию они были бы в пределах изменения параметра). `ggplot(mtcars, aes(mpg, hp, color = gear, group=gear)) + geom_point(size = 3) + geom_line(color = "black linetype = "dashed")` задает линейные графики для каждого значения переменной gear.




Рис. 3: Графики qplot для зависимости mpg от hp с facets

Интерактивные графики ggvis

Для этого нам понадобятся библиотеки ggvis, shiny, dplyr и ряд вспомогательных библиотек. Интерфейс достаточно прост. Рассмотрим, например, построение ядерной оценки плотности для переменной wt базы mtcars:

```
mtcars %>% ggvis(~wt) %>% layer_densities(adjust = input_slider(0.1, 3, value = 1))
mtcars описывает выбранную базу, ~wt — переменную графика, layer_densities — геометрию графика (построение плотности), а input_slider позволяет не задавать напрямую шаг ядерного слаживания, а меняя его с помощью слайдера на экране. Меняя положение слайдера мы можем сделать оценку удовлетворительной. Кроме input_slider имеются и другие способы задания параметров: input_checkbox(), input_checkboxgroup(), input_numeric(), input_radiobuttons(), input_select(), input_text().
```

Пример 3. `mtcars %>% ggvis(~wt) %>% layer_densities(adjust = input_slider(0.1, 2, value = 1, step = 0.1, label = "Bandwidth adjustment"), kernel = input_select(c("Gaussian" = "gaussian", "Epanechnikov" = "epanechnikov", "Rectangular" = "rectangular", "Triangular" = "triangular", "Biweight" = "biweight", "Cosine" = "cosine", "Optcosine" = "optcosine"), label = "Kernel"))`

Можно использовать в input_slider параметр map, преобразующий введенный пользователем параметр по заданной формуле, например, `mtcars %>% ggvis(~wt) %>% layer_densities(adjust = input_slider(1, 20, value = 10, map = function(x) x/10))`

Если вы хотите привязать один slider к нескольким графикам, то можете сперва положить input_slider в некоторую переменную, а затем использовать ее в нескольких графиках.

Полезной функцией является также add_tooltip. Скажем, `mtcars %>% ggvis(~wt, ~mpg) %>% layer_points() %>% add_tooltip(function(df) c(df$wt, " ", df$mpg))` позволит при наведении на точку увидеть ее координаты.




Рис. 4: Интерактивный график плотности с возможностью изменения типа ядра и шага