

МАШИННОЕ ОБУЧЕНИЕ  
ЛАБОРАТОРНЫЙ ПРАКТИКУМ  
(предварительный вариант)

Н.Ю. Золотых, А.Н. Половинкин, С.Н. Чернышова

9 октября 2007 г.

# 1. Практическое машинное обучение

## 1.1. Проверка статистических гипотез

### 1.1.1. Тест Шапиро–Уилка

Функция

```
shapiro.test(x)
```

выполняет тест Шапиро–Уилка. Нуль-гипотеза заключается в том, что случайная величина, выборка  $x$  которой известна, распределена по нормальному закону. Объем выборки должен быть не меньше 3 и не больше 5000.

Рассмотрим несколько примеров. Протестируем стандартные датчики распределений. Начнем с нормального распределения.

```
> set.seed(0)
> shapiro.test(rnorm(100, mean = 2, sd = 5))
```

Shapiro-Wilk normality test

```
data:  rnorm(100, mean = 2, sd = 5)
W = 0.9896, p-value = 0.6303
```

При уровне значимости, например,  $\alpha = 0.05$  гипотеза должна быть принята, так как  $p\text{-value} > \alpha$ .

Теперь рассмотрим равномерное распределение.

```
> set.seed(0)
> shapiro.test(runif(100, min = -10, max = 10))
```

Shapiro-Wilk normality test

```
data:  runif(100, min = -10, max = 10)
W = 0.9561, p-value = 0.002126
```

При уровне значимости, например,  $\alpha = 0.05$  гипотеза должна быть отвергнута, так как  $p\text{-value} < \alpha$ .

Рассмотрим еще один пример. Фрейм данных `trees` из библиотеки `datasets` содержит замеры диаметра, высоты и объема вишневых деревьев. Проверим гипотезу о том, что высоты деревьев распределены по нормальному закону.

```
> colnames(trees)
[1] "Girth" "Height" "Volume"
> x <- trees[, "Height"]
```

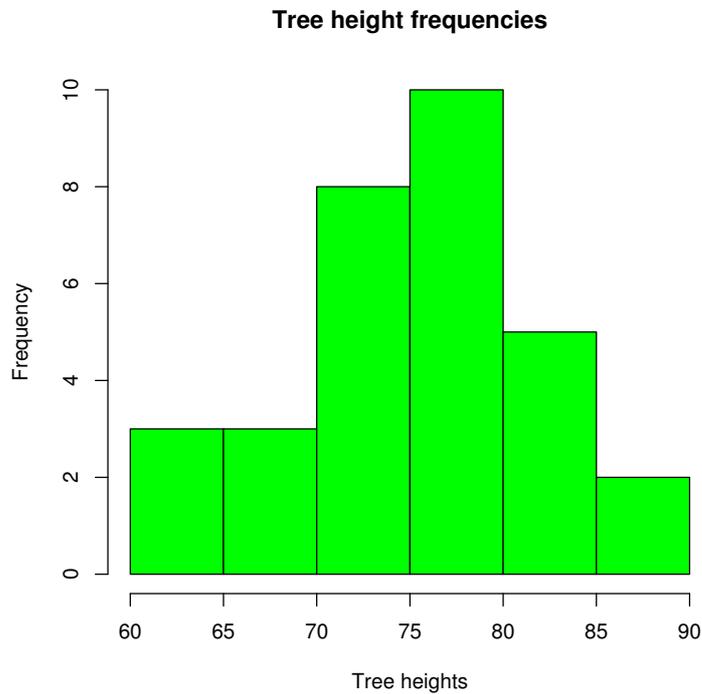


Рис. 1.1. Гистограмма представляет частоты высот вишневых деревьев

```
> hist(x, col = "green", xlab = "Tree heights",
      main = "Tree height frequencies")
> shapiro.test(x)
```

Shapiro-Wilk normality test

```
data: x
W = 0.9655, p-value = 0.4034
```

При уровне значимости, например,  $\alpha = 0.05$  гипотезу о нормальности распределения принимаем. Гистограмма представлена на рис. 1.1.

Объект, возвращаемый функцией `shapiro.test`, — это список со следующими полями:

- `statistics` — значение статистики Шапиро–Уилка,
- `p.value` — p-value,
- `method` — строка "Shapiro-Wilk normality test",
- `data.name` — строка, содержащее имя данных, подвергнутых тесту (в предыдущем примере `x`).

### 1.1.2. Критерий Колмогорова–Смирнова

*Описание:*

```
ks.test(x, y, ...,
        alternative = c("two.sided", "less", "greater"),
        exact = NULL)
```

Одно- или двухвыборочный тест Колмогорова–Смирнова.

$x$  — вектор, содержащий выборку.  $y$  — вектор, содержащий вторую выборку, или символьная строка с именем распределения. ... — параметры распределения. `alternative` — одно из следующих значений: `"two.sided"` (по умолчанию), `"less"`, or `"greater"`, обозначающих тип альтернативной гипотезы. См. детали ниже. `exact` — `NULL` или логическое значение, обозначающее требуется ли точное вычисление  $p$ -value. См. детали ниже. Не используется в двухвыборочном тесте, если `alternative = "less"` или `alternative = "greater"`.

*Детали:* Если  $y$  — числовой вектор, то выполняется двухвыборочный тест Колмогорова–Смирнова, проверяющий нуль-гипотезу о том, что  $x$  и  $y$  выбраны из одного непрерывного распределения.

Если  $y$  — строка, содержащая имя непрерывного распределения, то выполняется одновыборочный тест Колмогорова–Смирнова, проверяющий нуль-гипотезу о том, что  $x$  имеет заданное непрерывное распределение.

Возможные значения `"two.sided"`, `"less"` и `"greater"` параметра `alternative` определяют альтернативную гипотезу, которая может заключаться в том, что интегральная функция распределения выборки  $x$  не совпадает с гипотетической (`"two.sided"`), не больше ее (`"less"`) или не меньше ее (`"greater"`).

Точное  $p$ -value не вычисляется в двухвыборочном тесте, если `alternative = "less"` или `alternative = "greater"`. Если `exact = NULL` (по умолчанию), то точное  $p$ -value вычисляется, если объем выборки меньше 100 в одновыборочном тесте или если объемы выборок меньше 10000 в двухвыборочном тесте.

В одновыборочном тесте параметры гипотетического распределения должны быть известны точно, а не вычисляться по выборке  $x$ . Вариант теста Колмогорова–Смирнова с оценкой параметров не поддерживается.

Объект, возвращаемый функцией `ks.test`, — это список со следующими полями:

```
statistics — значение статистики Колмогорова–Смирнова,
p.value — p-value,
alternative — символьная строка с описанием альтернативной гипотезы,
method — символьная строка с названием используемого метода,
data.name — строка, содержащее имя данных, подвергнутых тесту.
```

Рассмотрим пример. Фрейм данных `randu` из библиотеки `datasets` содержит 400 троек псевдо-случайных чисел из интервала  $[0, 1]$ , последовательно выдаваемых (печально) известной функцией `RANDU`, имеющейся в компиляторе VAX FORTRAN под операционной системой VMS 1.5. Значения записаны в матрицу с тремя столбцами, называемыми именами  $x$ ,  $y$ ,  $z$ .

```
> colnames(randu)
[1] "x" "y" "z"
```

```
> nrow(randu)
[1] 400
> attach(randu)
> detach(randu)
> ks.test(x, y)
```

Two-sample Kolmogorov-Smirnov test

```
data: x and y
D = 0.085, p-value = 0.1111
alternative hypothesis: two-sided
```

```
Warning message:
cannot compute correct p-values with ties in: ks.test(x, y)
> ks.test(x, z)
```

Two-sample Kolmogorov-Smirnov test

```
data: x and z
D = 0.0875, p-value = 0.09353
alternative hypothesis: two-sided
```

```
> ks.test(y, z)
```

Two-sample Kolmogorov-Smirnov test

```
data: y and z
D = 0.0475, p-value = 0.7576
alternative hypothesis: two-sided
```

```
> ks.test(x, punif)
```

One-sample Kolmogorov-Smirnov test

```
data: x
D = 0.0555, p-value = 0.1697
alternative hypothesis: two-sided
```

```
> ks.test(y, punif)
```

One-sample Kolmogorov-Smirnov test

```
data: y
D = 0.0357, p-value = 0.6876
alternative hypothesis: two-sided
```

```

> ks.test(z, punif)

      One-sample Kolmogorov-Smirnov test

data:  z
D = 0.0455, p-value = 0.3782
alternative hypothesis: two-sided
> detach(randu)

```

### 1.1.3. *t*-тест Стьюдента

*Описание:*

```

t.test(x, ...)
t.test(x, y = NULL,
       alternative = c("two.sided", "less", "greater"),
       mu = 0, paired = FALSE, var.equal = FALSE,
       conf.level = 0.95, ...)
t.test(formula, data, subset, na.action, ...)

```

Выполняет одно- или двухвыборочный *t*-тест. Одновыборочный *t*-тест предназначен для проверки равенства среднего значения нормально распределенной генеральной совокупности некоторому заданному значению в предположении, что дисперсия не известна. Двухвыборочный тест служит для сравнения двух средних значений из нормально распределенных генеральных совокупностей в предположении, что их дисперсии равны, хотя и не известны.

*Аргументы:*

- `x` — вектор, содержащий данные (первая выборка).
- `y` — вектор, содержащий данные (вторая выборка) — опционально.
- `alternative` — одно из следующих значений: `"two.sided"` (по умолчанию), `"less"`, or `"greater"`, обозначающих тип альтернативной гипотезы.
- `exact` — `NULL` или логическое значение, обозначающее требуется ли точное вычисление *p*-value. Не используется в двухвыборочном тесте, если `alternative = "less"` или `alternative = "greater"`.
- `mu` — математическое ожидание или разность математических ожиданий, если задано две выборки.
- `paired` — логическое значение, указывающее, требуется ли выполнить спаренный *t*-тест.
- `var.equal` — логическое значение, считающее, считать ли разбросы равными. Если `TRUE`, то вычисляется разброс для объединенной выборки.
- `conf.level` — доверительный уровень.
- `formula` — формула вида `lhs ~ rhs`, где `lhs` — числовой вектор, а `rhs` — фактор с двумя классами. Только для двухвыборочного теста.
- `data` — матрица или фрейм данных, из которых берутся данные (опционально).
- `subset` — вектор, определяющий используемое подмножество наблюдений.
- `na.action` — функция, которая вызывается, как только в данных встретит-

лось значение NA.

**Детали:** Если `y` и `formula` не заданы, то выполняется одновыборочный тест, проверяющий, что выборка `x` имеет среднее, равное 0.

Если `paired = TRUE`, то должны быть определены и иметь одинаковую длину векторы `x` и `y`.

Значения NA и NaN из данных удаляются (если `paired = TRUE`, то при этом удаляется соответствующее значение из второй выборки).

Если `var.equal = TRUE`, то для оценки отклонения используется объединенная выборка. По умолчанию `var.equal = FALSE` и отклонение оценивается отдельно для каждой выборки. При этом происходит надлежащая корректировка числа степеней свободы.

**Возвращаемое значение:** Объект, возвращаемый функцией `t.test`, — это список со следующими полями:

- `statistics` — значение  $t$ -статистики Стьюдента,
- `parameter` — число степеней свободы,
- `p.value` — p-value,
- `conf.int` — доверительный интервал для математического ожидания,
- `estimate` — оценка математического ожидания для одновыборочного теста или разности математических ожиданий для двувыборочного теста,
- `null.value` — предполагаемое математическое ожидание или разность предполагаемых математических ожиданий для двувыборочного теста (входной параметр  $\mu$ ),
- `alternative` — символьная строка с описанием альтернативной гипотезы,
- `method` — символьная строка с названием используемой модификации метода,
- `data.name` — строка, содержащее имя (имена) данных, подвергнутых тесту.

**Примеры:** В качестве простых примеров сравним математические ожидания у двух выборок, полученных с помощью функции `rnorm`:

```
> set.seed(0)
> x <- rnorm(100, mean = 0, sd = 4)
> y <- rnorm(100, mean = 1, sd = 4)
```

Итак, `x` и `y` — две выборки из нормальных генеральных совокупностей с одинаковым среднеквадратическим отклонением, но разными средними. Применим к выборкам  $t$ -тест, полагая, что в качестве нуль-гипотезы постулируется, что генеральные совокупности имеют одинаковое среднее. Альтернативная гипотеза пусть утверждает, что средние не равны.

```
> t.test(x, y)
```

```
Welch Two Sample t-test
```

```
data: x and y
t = -1.3896, df = 196.428, p-value = 0.1662
alternative hypothesis: true difference in means is not equal to 0
```

```
95 percent confidence interval:
-1.7590435  0.3048036
sample estimates:
mean of x mean of y
0.0906738  0.8177938
```

Дадим разъяснение полученным результатам. Найдено значение статистики  $t$ , число степеней свободы  $df$ , величина  $p$ -value. Указаны границы 95% доверительного интервала для разности мат. ожиданий первого и второго распределений. Приведены оценки математических ожиданий для каждого распределения. Пусть уровень значимости равен  $\alpha = 0.1$ . Так как  $p$ -value  $> \alpha$ , то гипотезу о том, что математические ожидания  $y$  распределений равны, принимаем.

Изменим теперь альтернативную гипотезу. Пусть альтернативная гипотеза постулирует, что вторая генеральная совокупность имеет большее математическое ожидание, чем первая:

```
> t.test(x, y, alternative = "less")

Welch Two Sample t-test

data:  x and y
t = -1.3896, df = 196.428, p-value = 0.08311
alternative hypothesis: true difference in means is less than 0
95 percent confidence interval:
 -Inf 0.1376404
sample estimates:
mean of x mean of y
0.0906738  0.8177938
```

Теперь при уровне значимости  $\alpha = 0.1$ , так как  $p$ -value  $< \alpha$ , то нуль-гипотезу отклоняем и принимаем альтернативную гипотезу.

В качестве еще одного примера рассмотрим данные об измерениях скорости света, полученные А.А. Майкельсоном и Э.У. Морли во время знаменитого эксперимента 1887 г. Данные содержатся во фрейме `morley` библиотеки `datasets`. Фрейм содержит три столбца: `Expt` — номер эксперимента (от 1 до 5), `Run` — номер испытания (каждый эксперимент состоял из 20 испытаний), `Speed` — скорость света минус 299000 (в км/с). Примем во внимание только последний столбец. Предположим, что генеральная совокупность (замеры скорости света) имеет нормальное распределение. Сформулируем нуль-гипотезу: математическое ожидание генеральной совокупности равно 299792.458 (принятое в настоящее время значение скорости света).

```
> t.test(light - 792.458)

One Sample t-test

data:  light - 792.458
```

```

t = 7.5866, df = 99, p-value = 1.824e-11
alternative hypothesis: true mean is not equal to 0
95 percent confidence interval:
 44.26459 75.61941
sample estimates:
mean of x
 59.942

```

Дадим разъяснение полученным результатам. Найдено значение статистики  $t$ , число степеней свободы  $df$ , величина  $p$ -value. Указаны границы 95% доверительного интервала для оценки мат. ожидания выборки `light` — 792.458. Приведены оценки математических ожиданий для каждой группы. Пусть уровень значимости равен  $\alpha = 0.05$ . Так как  $p$ -value  $< \alpha$ , гипотезу отклоняем.

Рассмотрим классический пример Стьюдента. Фрейм данных `sleep` из библиотеки `datasets` содержит информацию об увеличении продолжительности сна у 10 пациентов, которым давали два типа снотворного. У фрейма `sleep` 20 строк и два столбца с именами `extra` и `group`. В первом столбце содержатся числовые значения, равные увеличению продолжительности сна (в часах) после принятия снотворного, во втором столбце — тип снотворного (`factor`).

```

> colnames(sleep)
[1] "extra" "group"
> nrow(sleep)
[1] 20
> plot(extra ~ group, data = sleep, col = c("gold", "coral"))

```

Графический результат представлен на рис. 1.2.

В качестве нуль-гипотезы возьмем утверждение, что данные из первой и второй группы имеют одинаковое среднее (при условии, что обе выборки удовлетворяют нормальному закону распределения). Альтернативная гипотеза будет заключаться в том, что средние не совпадают.

```

> t.test(extra ~ group, data = sleep)
Welch Two Sample t-test

data:  extra by group
t = -1.8608, df = 17.776, p-value = 0.0794
alternative hypothesis: true difference in means is not equal to 0
95 percent confidence interval:
 -3.3654832  0.2054832
sample estimates:
mean in group 1 mean in group 2
      0.75          2.33

```

Дадим разъяснение полученным результатам. Найдено значение статистики  $t$ , число степеней свободы  $df$ , величина  $p$ -value. Указаны границы 95% доверительного интервала для оценки разности мат. ожиданий. Приведены оценки математических ожиданий для каждой группы.

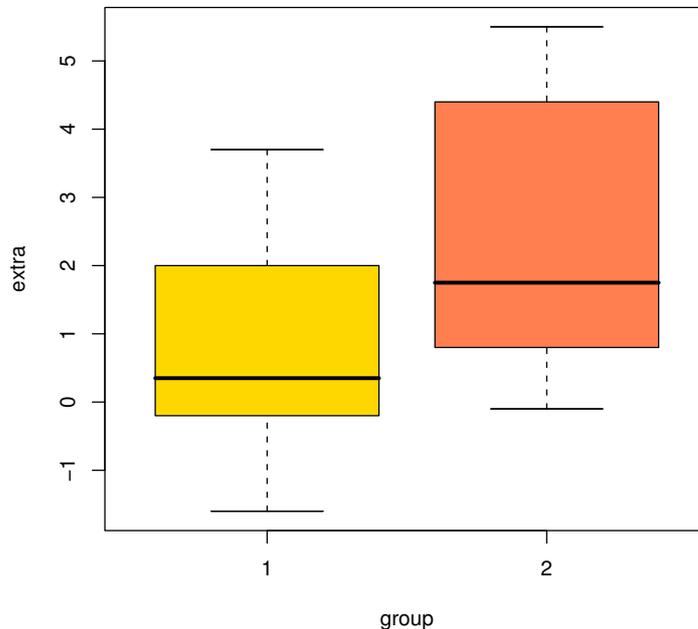


Рис. 1.2. Влияние двух типов снотворного на изменение продолжительности сна

Пусть выбран уровень значимости  $\alpha = 0.05$ . Мы видим, что  $\alpha < p\text{-value}$ , таким образом, гипотезу о том, что данные имеют разные распределения принять нельзя.

Изменим альтернативную гипотезу и посмотрим, как это повлияет на p-value. Пусть теперь альтернативная гипотеза постулирует, что мат. ожидание второго распределения больше мат. ожидания первого распределения.

```
> t.test(extra ~ group, data = sleep, alternative = "less")
Welch Two Sample t-test
data: extra by group
t = -1.8608, df = 17.776, p-value = 0.0397
alternative hypothesis: true difference in means is less than 0
95 percent confidence interval:
 -Inf -0.1066185
sample estimates:
mean in group 1 mean in group 2
      0.75          2.33
```

Теперь при том же уровне значимости  $\alpha = 0.05$  мы должны отклонить нуль-гипотезу и принять альтернативную гипотезу. На содержательном языке альтернативная гипотеза говорит о том, что второе снотворное приводит к боль-

шему увеличению продолжительности сна, чем первое.

#### 1.1.4. *F*-тест Фишера

```
var.test(x, y, ratio = 1,
         alternative = c("two.sided", "less", "greater"),
         conf.level = 0.95, ...)
var.test(formula, data, subset, na.action, ...)
```

Выполняет *F*-тест Фишера для проверки на равенство стандартных отклонений двух нормально распределенных генеральных совокупностей.

##### **Аргументы:**

`x`, `y` — числовые векторы, содержащие выборки из разных генеральных совокупностей, или линейные модели (возвращаемые функцией `lm`).

`ratio` — предполагаемая величина отношения стандартных отклонений в первой и второй генеральных совокупностях.

`alternative` — одно из следующих значений: `"two.sided"` (по умолчанию), `"less"`, or `"greater"`, обозначающих тип альтернативной гипотезы.

`conf.level` — доверительный уровень для возвращаемого доверительного интервала.

`formula` — формула вида `lhs ~ rhs`, где `lhs` — числовой вектор, а `rhs` — фактор с двумя классами.

`data` — матрица или фрейм данных, из которых берутся данные для `formula` (опционально).

`subset` — вектор, определяющий используемое подмножество наблюдений.

`na.action` — функция, которая вызывается, как только в данных встретилось значение NA.

**Детали:** Нуль-гипотеза постулирует, что отношение стандартных отклонений генеральных совокупностей, из которых выбраны  $x$  и  $y$  соответственно, равна отношению *ratio*.

**Возвращаемое значение:** Объект, возвращаемый функцией `var.test`, — это список со следующими полями:

`statistics` — значение *F*-статистики Фишера,

`parameter` — число степеней свободы,

`p.value` — p-value,

`conf.int` — доверительный интервал для математического ожидания,

`estimate` — оценка математического ожидания для одновыборочного теста или разности математических ожиданий для двухвыборочного теста,

`null.value` — предполагаемое математическое ожидание или разность предполагаемых математических ожиданий для двухвыборочного теста (входной параметр  $\mu$ ),

`alternative` — символьная строка с описанием альтернативной гипотезы,

`method` — символьная строка с названием используемой модификации метода,

`data.name` — строка, содержащее имя (имена) данных, подвергнутых тесту.

**Примеры:** Рассмотрим две выборки из разных нормальных генеральных совокупностей:

```
> x <- rnorm(50, mean = 0, sd = 2)
> y <- rnorm(50, mean = 10, sd = 2)
```

Проверим, что генеральные совокупности имеют одинаковое стандартное отклонение.

```
> var.test(x, y)

      F test to compare two variances

data:  x and y
F = 0.7353, num df = 49, denom df = 49, p-value = 0.2852
alternative hypothesis: true ratio of variances is not equal to 1
95 percent confidence interval:
 0.4172619 1.2957270
sample estimates:
ratio of variances
 0.7352942
```

Пусть, например, уровень значимости равен  $\alpha = 0.05$ . Так как  $\alpha < p\text{-value}$ , то гипотезу о равенстве стандартных отклонений принимаем.

Вернемся к примеру Стьюдента с данными о влиянии разных снотворных на продолжительность сна. Теперь сравним стандартные отклонения. Вначале в качестве альтернативной возьмем гипотезу (по умолчанию), что отношение стандартных отклонений не равно 1:

```
> var.test(extra ~ group, data = sleep)

      F test to compare two variances

data:  extra by group
F = 0.7983, num df = 9, denom df = 9, p-value = 0.7427
alternative hypothesis: true ratio of variances is not equal to 1
95 percent confidence interval:
 0.198297 3.214123
sample estimates:
ratio of variances
 0.7983426
```

Пусть, например, уровень значимости равен  $\alpha = 0.1$ . Так как  $\alpha < p\text{-value}$ , то гипотезу о равенстве стандартных отклонений принимаем.

Теперь в качестве альтернативной возьмем гипотезу, что отношение отклонений меньше 1:

```
> var.test(extra ~ group, data = sleep, alternative = "less")
```

## F test to compare two variances

```
data: extra by group
F = 0.7983, num df = 9, denom df = 9, p-value = 0.3714
alternative hypothesis: true ratio of variances is less than 1
95 percent confidence interval:
 0.000000 2.537846
sample estimates:
ratio of variances
 0.7983426
```

При уровне значимости  $\alpha = 0.1$  гипотезу о равенстве стандартных отклонений снова принимаем.

### 1.1.5. Критерий согласия $\chi^2$ Пирсона

*Описание:*

```
chisq.test(x, y = NULL, correct = TRUE,
           p = rep(1/length(x), length(x)), rescale.p = FALSE,
           simulate.p.value = FALSE, B = 2000)
```

Функция реализует критерий согласия  $\chi^2$  Пирсона для простых гипотез и тест на проверку независимости признаков.

*Аргументы:*

`x` — вектор или матрица.

`y` — вектор. Игнорируется, если `x` — матрица.

`correct` — логическое значение, указывающее, требуется ли применять непрерывную коррекцию для  $2 \times 2$  матриц.

`p` — вектор, содержащий вероятности. Должен иметь такую же длину, что и `x`.

`rescale.p` — логическое значение. Если `TRUE`, то `p` при необходимости масштабируется, так, чтобы сумма его компонентов была равна 1.

`simulate.p.value` — логическое значение. Если `TRUE`, то `p-value` вычисляется с помощью метода Монте-Карло, в противном случае используется  $\chi^2$  распределение.

`B` — количество испытаний в методе Монте-Карло.

*Детали:* Если `x` — вектор или матрица с одним столбцом или одной строкой, а вектор `y` не задан, то `x` рассматривается как статистический ряд (одномерная таблица сопряженности признаков), т. е.  $i$ -я компонента вектора `x` содержит количество точек попавших в  $i$ -й интервал группировки. В этом случае выполняется тест на проверку согласия данных заданным вероятностям `p`. Таким образом, нуль-гипотеза заключается в том, что вероятность попадания в  $i$ -й интервал группировки равна  $i$ -й компоненте вектора `p`. По умолчанию, задаются равные вероятности.

Если `x` — матрица не менее чем с 2 строками и 2 столбцами, то `x` рассматривается как двумерная таблица сопряженности признаков и выполняется тест на проверку их независимости.

Итак, обратим внимание, что если аргумент `y` не задан, то функция `chisq.test` работает со статистическим рядом или таблицей сопряженности, а не с выборкой.

Если `x` и `y` числовые векторы или векторы факторов одной и той же длины (числовые векторы конвертируются в векторы факторов), то соответствующие пары их компонентов рассматриваются как реализации двумерной случайной величины  $(X, Y)$  и выполняется тест на проверку независимости признаков  $X$  и  $Y$ .

**Возвращаемое значение:** Объект, возвращаемый функцией `chisq.test`, — это список со следующими полями:

- `statistics` — значение  $\chi^2$ -статистики Пирсона,
- `parameter` — число степеней свободы распределения  $\chi^2$ ; равно `NA`, если для отыскания `p-value` использовался метод Монте-Карло,
- `p.value` — `p-value`,
- `method` — символьная строка с названием используемой модификации теста, а также указанием того, использовались ли непрерывная коррекция и метод Монте-Карло,
- `data.name` — строка, содержащее имя (имена) данных, подвергнутых тесту,
- `observed` — число точек, попавших в  $i$ -й интервал группировки (равно `x` на входе, если `x` — вектор, а `y` не используется),
- `expected` — теоретическое число точек (в предположении выполнения гипотезы), попавших в  $i$ -й интервал группировки,
- `residuals` — остатки Пирсона:

$$\frac{\text{observed} - \text{expected}}{\sqrt{\text{expected}}}.$$

**Примеры:** Рассмотрим классический пример с бросанием монеты. Бюффон бросал монету 4040 раз, при этом герб выпал 2048 раз. Используя критерий согласия  $\chi^2$ , проверим, что монета симметрична. Итак, нуль-гипотеза заключается в том, что вероятность выпадения герба равна  $p_1 = 1/2$ , вероятность выпадения решки —  $p_2 = 1/2$ .

```
> chisq.test(c(2048, 1992))
```

Chi-squared test for given probabilities

```
data: c(2048, 1992)
X-squared = 0.7762, df = 1, p-value = 0.3783
```

Пусть, например, был выбран уровень значимости  $\alpha = 0.05$ . Так как  $\alpha < p\text{-value}$ , то гипотезу принимаем.

Рассмотрим простой пример на проверку независимости двух генеральных совокупностей, если известны выборки `x`, `y`. Соответствующие пары компонентов векторов `x`, `y` требуется рассматривать как реализации двумерной случайной величины  $(X, Y)$ .

```
> set.seed(0)
```

```
> x <- rnorm(100)
> y <- runif(100)
> chisq.test(x, y)
```

Pearson's Chi-squared test

```
data: x and y
X-squared = 9900, df = 9801, p-value = 0.239
```

Warning message:

```
Chi-squared approximation may be incorrect in: chisq.test(x, y)
```

Пусть, например, был выбран уровень значимости  $\alpha = 0.05$ . Так как  $\alpha < p$ -value, то гипотезу о независимости случайных признаков принимаем.

Рассмотрим пример на проверку независимости двух случайных величин. Таблица `HairEyeColor` из библиотеки `datasets` содержит информацию о поле, цвете волос и глаз у 592 студентов. Таблица имеет 3 размерности:

```
"Hair": HairEyeColor["Black", ,], HairEyeColor["Brown", ,], HairEyeColor["Red", ,],
HairEyeColor["Blond", ,],
"Eye": HairEyeColor[, "Brown",], HairEyeColor[, "Blue",], HairEyeColor[, "Hazel",],
HairEyeColor[, "Green",],
"Sex": HairEyeColor[, , "Male"], HairEyeColor[, , "Female"].
```

Элементы таблицы — количество человек из данной группы. Проверим нуль-гипотезу о том, что общее цвет глаз мужчин не зависит от цвета волос мужчин. Во-первых, построим таблицу сопряженности признаков:

```
> men <- HairEyeColor[, , "Male"]
> men
      Eye
Hair  Brown Blue Hazel Green
Black   32   11   10    3
Brown   38   50   25   15
Red     10   10    7    7
Blond    3   30    5    8
> mosaicplot(men,
  col = c("chocolate", "cornflowerblue", "salmon", "green"),
  main = "Male eye color vs. hair color")
> chisq.test(men, simulate.p.value = TRUE)
```

Pearson's Chi-squared test with simulated p-value  
(based on 2000 replicates)

```
data: men
X-squared = 42.1633, df = NA, p-value = 0.0004998
```

При уровне значимости, например,  $\alpha = 0.05$ , гипотезу следует отклонить и признаки считать зависимыми. Построенная мозаичная диаграмма приведена на рис. 1.3. Аналогичные результаты можно получить и для женщин.

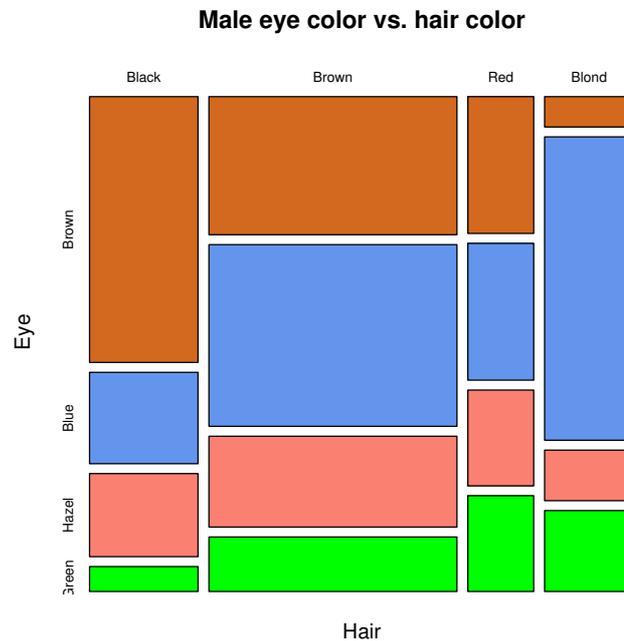


Рис. 1.3. Зависимость цвета глаз от цвета волос у мужчин

### 1.1.6. Задания для лабораторной работы

- 1) Используя тест Шапиро-Уилка, проверьте, являются ли нормально распределенными характеристики цветов ириса (фрейм данных `iris`). Уровень значимости  $\alpha = 0.05$ .
- 2) Для  $k=10, 15, 20, 25, 30$  сгенерируйте 200 реализаций нормальной распределенной случайной величины с мат. ожиданием, равным  $k$ , и стандартным отклонением, равным  $\sqrt{2k}$ , и 200 реализаций случайной величины, распределенной по закону  $\chi^2$  с  $k$  степенями свободы. Используя тест Колмогорова-Смирнова, проверьте гипотезу о том, что данные выборки относятся к одному непрерывному распределению. Уровень значимости  $\alpha = 0.05$ .
- 3) Загрузите таблицу из файла `allcountries.txt`, содержащую информацию о населении, площади и ряде других характеристик современных государств. Выберите из таблицы те страны, для которых доступна информация о населении и площади (нет отсутствующих значений NA) и площадь больше 10.0. Пусть `area_log = log10(log10(area))`, `population_log = log10(log10(population))`. Постройте линейную регрессию (используя функцию `lm`) для зависимости `population_log` от

`area_log`. Используя тест Колмогорова-Смирнова, проверьте гипотезу о том, что `population_log` и `f(area_log)`, где `f()` — построенная регрессионная функция, относятся к одному непрерывному распределению. Уровень значимости  $\alpha = 0.05$ .

- 4) Используя критерий  $\chi^2$  проверьте нуль-гипотезу, состоящую в том, что цвет глаз женщин не зависит от цвета волос (на фрейме данных `HairEyeColor`).
- 5) Загрузите таблицу из файла `readingspeed.txt`, которая содержит информацию о скорости чтения у детей в зависимости от применяемой методики обучения (`DRA` — direct reading activities, `SC` — standart curriculum). Используя t-тест, проверьте гипотезу о том, что среднее время чтения для обеих методик совпадает (используйте разные альтернативные гипотезы). Объясните полученные результаты.