

значения критических точек для  $F$  распределения можно найти также и в интернете.

**2.6. Объяснение критерия Фишера.** Можно показать, что при выполнении гипотезы  $H_0$  обе величины  $SS_{\text{TR}} / (k-1)$  и  $SS_{\text{E}} / (n-k)$  являются “хорошими” статистическими оценками теоретической дисперсии  $\sigma^2$ . Это, в частности означает, что их отношение близко к 1. Если же  $H_0$  не верна, то  $SS_{\text{TR}} / (k-1)$  с большой вероятностью становится больше  $SS_{\text{E}} / (n-k)$ , так как различия между группами становятся доминирующими. Таким образом, большие значения отношения  $F$  в (2) свидетельствуют о том, что гипотеза  $H_0$  не верна. Критическая величина  $F$ , при котором “доверие” к  $H_0$  становится слишком низким, равна  $F_{\alpha; k-1, n-k}$ . Степень достоверности принятия такого решения определяется уровнем  $\alpha$ .

*Замечание 4.* Хотя приведенные выше сведения о критерии Фишера и распределении Фишера относятся к конкретным значениям  $k = 4$ ,  $n_1 = 65$ ,  $n_2 = 56$ ,  $n_3 = 52$  и  $n_4 = 76$ , все рассуждения, формулы и результаты остаются справедливыми и для произвольного количества групп и произвольного количества наблюдений в каждой группе.

### 3. ПРОВЕРКА ГИПОТЕЗЫ ДЛЯ ИССЛЕДОВАНИЯ ЛЬЮИСА

Вернемся к исследованию Льюиса.

Нашей задачей является проверка гипотезы о том, что профилактический прием витамина С **не** снижает риск простуды и **не** уменьшает длительность заболевания (см. замечание 1).

К сожалению необходимые для этого данные — длительность  $j$ -ого заболевания в  $i$ -ой группе  $X_{ij}$  — в отчете Льюиса и его коллег не приведены. Поэтому проверить указанную гипотезу с помощью критерия Фишера не представля-

ется возможным. Более внимательный анализ отчета Льюиса все же показывает, что в нем содержится немного больше информации, чем в таблице 2. В оригинальной таблице Льюиса средние длительности простуд приведены для каждой группы в виде  $\bar{X}_i \pm \hat{\sigma}_i$ , то есть с точностью до одного *среднеквадратического отклонения*  $\hat{\sigma}_i$ , которое определяется как корень квадратный из выборочной дисперсии  $\hat{\sigma}_i^2$ :

$$(5) \quad \hat{\sigma}_i^2 = \frac{1}{n_i - 1} \sum_{j=1}^{n_i} (X_{ij} - \bar{X}_i)^2, \quad 1 \leq i \leq 4.$$

Заметим, что сумма величин  $(n_i - 1)\hat{\sigma}_i^2$  по  $i = 1, 2, 3, 4$  обозначалась выше символом  $SS_{TO}$ .

Таким образом мы фактически обладаем следующей информацией:

#### Т а б л и ц а 4

##### Эмпирические характеристики

	Группа 1	Группа 2	Группа 3	Группа 4
$n_i$	65	56	52	76
$\bar{X}_i$	7.1	6.5	6.7	5.9
$\hat{\sigma}_i$	0.46	0.39	0.53	0.40
$\hat{\sigma}_i^2$	0.21	0.15	0.28	0.16

В этой таблице  $n_i$  — это количество простудных заболеваний в  $i$ -ой группе,  $\bar{X}_i$  — средняя длительность заболеваний,  $\hat{\sigma}_i^2$  — эмпирическая дисперсия, вычисленная по формуле (5).

Все же и этой информации недостаточно, чтобы вычислить суммы квадратов  $SS_{TO}$ ,  $SS_{TR}$  и  $SS_E$ . Чтобы решить поставленную задачу проверки гипотезы, мы поступим следующим образом: сначала для каждой группы  $i$  смоделируем на компьютере  $n_i$  наблюдений с распределением  $\mathcal{N}(\bar{X}_i, \hat{\sigma}_i^2)$ . Затем используем полученные данные для проверки гипотезы.

*Замечание 5.* Для того, чтобы обоснованно пользоваться критерием Фишера, необходимо быть уверенным в истинности предположений 1–5. Предположение 4 требует, чтобы дисперсии были одинаковыми. В таблице 4 наибольшая дисперсия отвечает группе 3 ( $\sigma_3^2 = 0.281$ ), а наименьшая — группе 2 ( $\sigma_2^2 = 0.152$ ). Их отношение приблизительно равно 1.85. Хотя дисперсии отличаются почти в 2 раза, можно допустить что различие объясняется статистической изменчивостью данных. Гипотезу о равенстве дисперсий нескольких независимых гауссовских выборок можно проверить с помощью *критерия Хартли*, который в нашем случае не отвергает ее на уровне доверия 0.95. В дальнейшем считаем, что это является достаточным основанием справедливости предположения 4.

**3.1. Моделирование.** Необходимые данные сгенерируем с помощью команды СЛЧИС() программы Excel, которая генерирует значение случайной величины  $\mathbf{U}$ , имеющей равномерное распределение на отрезке  $(0, 1)$ . Ниже приведен алгоритм генерации одного значения случайной величины  $\mathbf{G}_{a,b^2}$ , имеющей распределение  $\mathcal{N}(a, b^2)$ :

1. сгенерировать 12 значений  $U_1, \dots, U_{12}$  случайной величины  $\mathbf{U}$ ;
2. вычислить  $G_{0,1} = b(U_1 + \dots + U_{12} - 6 + a)$ .

Результаты моделирования представлены в таблице 5, вид которой полностью идентичен таблице 3. Для генерации  $i$ -го столбца таблицы 5 указанная процедура применялась для параметров  $a = \bar{X}_i$  и  $b^2 = \hat{\sigma}_i^2$ , взятых из таблицы 4. Результаты моделирования были бы более адекватными, если бы оно проводилось не для эмпирических значений среднего  $\bar{X}_i$  и дисперсии  $\hat{\sigma}_i^2$ , а для их теоретических значений  $\mu_i$  и  $\sigma_i^2$ , но последние нам не известны.

Чтобы различать данные эксперимента Льюиса и сгенерированные данные, мы обозначаем последние через  $Y_{ij}$ .

Результаты всех вычислений с данными  $\{Y_{ij}\}$  также будут содержать букву  $Y$ . Например,  $\bar{Y}_1, \bar{Y}_2, \bar{Y}_3$  и  $\bar{Y}_4$  обозначают средние по группам, а  $\bar{Y}$  — общее среднее для всей таблицы.

**3.2. Проверка гипотезы.** Для подсчетов удобно пользоваться следующими обозначениями и формулами (хотя мы по-прежнему используем значение  $k = 4$ , формулы ниже справедливы и для другого количества групп):

$n_1, \dots, n_k$  количества наблюдений в группах,

$T_1, \dots, T_k$  суммы наблюдений по группам,

$$n = n_1 + \dots + n_k,$$

$$T = T_1 + \dots + T_k,$$

$$c \stackrel{\text{def}}{=} \frac{T^2}{n}.$$

Тогда

$$(6) \quad SS_{\text{TO}} = \sum_{i=1}^k \sum_{j=1}^{n_i} X_{ij}^2 - c,$$

$$(7) \quad SS_{\text{TR}} = \sum_{i=1}^k \frac{T_i^2}{n_i} - c,$$

$$(8) \quad SS_{\text{E}} = SS_{\text{TO}} - SS_{\text{TR}}.$$

Для данных из таблицы 5 имеем:

$$\begin{aligned} n_1 &= 65, & n_2 &= 56, & n_3 &= 52, & n_4 &= 76, \\ T_1 &= 466.18, & T_2 &= 362.44, & T_3 &= 351.45, & T_4 &= 451.20 \\ n &= 249, & T &= 1631.27, & c &= 10686.91, \\ SS_{\text{TO}} &= 105.38, & SS_{\text{TR}} &= 56.32, & SS_{\text{E}} &= 49.05. \end{aligned}$$

Т а б л и ц а 5

Сгенерированные данные

j	Y <sub>1j</sub>	Y <sub>2j</sub>	Y <sub>3j</sub>	Y <sub>4j</sub>	j	Y <sub>1j</sub>	Y <sub>2j</sub>	Y <sub>3j</sub>	Y <sub>4j</sub>
1.	7,72	6,56	6,21	6,40	39.	7,92	6,35	6,92	5,79
2.	7,76	6,19	6,83	6,07	40.	7,29	6,62	8,01	6,32
3.	7,36	6,11	7,75	6,06	41.	7,98	5,98	7,07	5,45
4.	7,41	6,95	6,18	6,37	42.	6,94	6,45	7,16	6,46
5.	7,28	6,84	6,87	6,04	43.	7,64	6,73	7,53	6,16
6.	7,03	5,98	6,43	6,90	44.	7,10	6,55	6,65	5,83
7.	7,51	6,57	6,86	5,81	45.	6,59	6,26	6,57	5,51
8.	7,69	6,78	6,82	5,80	46.	7,23	6,55	5,55	5,49
9.	7,50	7,53	7,00	5,56	47.	6,38	6,47	7,36	5,85
10.	7,12	6,24	6,03	5,15	48.	7,34	5,90	7,27	6,89
11.	7,71	5,87	6,75	5,74	49.	6,74	6,09	5,86	6,41
12.	7,00	6,57	7,15	6,48	50.	6,97	6,54	6,50	6,40
13.	7,80	6,09	7,09	6,70	51.	6,94	6,47	6,55	5,64
14.	6,10	6,12	6,82	5,72	52.	7,47	6,83	6,89	5,35
15.	7,63	7,18	7,22	5,45	53.	6,69	7,31		6,25
16.	7,11	7,07	6,44	5,96	54.	6,77	6,76		6,38
17.	7,55	5,97	6,85	5,68	55.	7,34	6,24		5,72
18.	7,88	5,94	6,60	6,16	56.	6,78	5,69		5,46
19.	7,66	6,36	6,36	5,48	57.	7,16			5,65
20.	6,75	7,50	7,91	5,72	58.	6,47			6,36
21.	6,51	7,16	7,05	5,75	59.	7,12			6,38
22.	7,06	6,32	6,83	5,83	60.	7,12			5,95
23.	6,74	6,22	5,52	5,90	61.	7,73			6,86
24.	7,27	6,44	6,54	5,62	62.	7,08			5,99
25.	7,70	6,89	6,55	5,82	63.	6,87			5,08
26.	6,35	6,41	6,96	6,12	64.	7,12			5,63
27.	7,62	6,02	6,93	5,79	65.	6,91			5,44
28.	7,12	6,50	6,85	5,33	66.				6,04
29.	7,09	7,06	6,03	5,59	67.				5,53
30.	7,38	5,54	6,19	5,65	68.				6,47
31.	7,27	6,28	6,84	6,67	69.				5,94
32.	7,09	6,90	6,04	5,60	70.				5,60
33.	7,08	6,46	7,22	6,43	71.				6,13
34.	6,83	6,35	7,32	5,59	72.				6,18
35.	7,02	6,26	6,72	5,89	73.				6,80
36.	7,23	6,68	6,91	5,74	74.				5,48
37.	6,44	6,06	6,22	5,66	75.				6,34
38.	7,12	6,68	6,67	5,91	76.				5,85

Для проверки гипотезы

$$H_0: \mu_1 = \mu_2 = \mu_3 = \mu_4$$

о том, что прием витамина С не оказывает влияния на продолжительность простуд, выберем достаточно высокий уровень доверия  $\alpha = 0.99$ .

Значение критической точки  $F_{0.99;3,245}$  в таблицах отсутствует. Однако ее значение находится между  $F_{0.99;3,120}$  и  $F_{0.99;3,\infty}$ , а эти квантили в таблицах имеются. Таким образом,  $3.78 < F_{0.99;3,245} < 3.95$ . По формуле (2) вычисляем значение тестовой статистики:

$$F = 93.77.$$

Поскольку  $F \geq F_{0.99;3,245}$ , то согласно критерию Фишера §2.5, гипотеза  $H_0$  отвергается в пользу альтернативы, которая состоит в том, что не все теоретические средние равны между собой. Это свидетельствует о том, что в эксперименте присутствует хотя-бы один фактор, который делает результаты разными в разных группах.

Более сильным выводом после проведенного дисперсионного анализа является утверждение о том, профилактический прием витамина С уменьшает длительность простуд.

## У П Р А Ж Н Е Н И Я

**Упражнение 1.** Доказать, что случайные величины  $\varepsilon_{ij}$  в (1) независимы, причем  $\varepsilon_{ij} \sim \mathcal{N}(0, \sigma^2)$ .

**Упражнение 2.** Интегрируя плотность распределения Фишера, доказать формулы (3) и (4).

**Упражнение 3.** Объяснить почему реализации нормальной случайной величины можно генерировать с помощью способа, описанного выше в §3.1.

**Упражнение 4.** Доказать равенства (6)–(8).