

УДК 519.233.3:633/635

А. Т. Хохрякова, студентка 1 курса агрономического факультета
Научный руководитель: старший преподаватель кафедры высшей математики Е. Н. Соболева ФГБОУ ВО Ижевская ГСХА

Проверка статистической гипотезы на примере растениеводства

В статье методами математической статистики произведена обработка двух выборок: длины пророщенных ростков пшеницы без применения нанокремния и с применением нанокремния. Сформированы интервальные ряды распределения по данным выборкам, подсчитаны выборочные характеристики и выполнены их точечные оценки. А также проверена гипотеза о том, значительно ли различаются средние длины пророщенных ростков пшеницы.

Глобальной проблемой общества является огромное количество информации и данных в повседневной жизни. Данная проблема позволила учёным открыть такую науку, как математическая статистика. Что такое математическая статистика? Какие существуют методы обработки данных и информации? Математическая статистика – это наука, которая изучает математические методы обработки и использования статистических данных для научных и экспериментальных выводов. В современном мире существует много разных методов. Например, корреляционный анализ, регрессионный анализ, статистическое оценивание параметров распределения и проверка статистических гипотез. Можно выделить такой актуальный метод, как проверка статистических гипотез. Данный метод основан на том, чтобы проверить согласуются ли выборочные данные с выдвинутой гипотезой при исследовании какого-либо признака.[1-7] В нашем эксперименте были измерены длины пророщенных ростков пшеницы без применения нанокремния и с применением нанокремния.

Цель эксперимента заключается в том, чтобы определить значительно или незначительно различаются длины пророщенных ростков пшеницы.

Задачи эксперимента:

1. Изучить основные понятия темы «Проверка статистических гипотез»;
2. Обработать данные по выборкам объёмом 50:
 - а) Построить интервальные ряды распределения по выборкам;
 - б) Вычислить выборочное среднее, выборочную дисперсию, выборочное среднее квадратическое отклонение;
3. На основе полученных данных проверить гипотезу о равенстве двух средних генеральных совокупностей (независимые выборки) при уровне значимости 0,01;
4. Сделать практические выводы.

Материалы и методы. Эксперимент проводился на злаковом растении пшеница (лат. *Triticum L.*) в лабораторных условиях. Были пророщены семена пшеницы с применением нанокремния и без применения нанокремния (рис.1, рис.2)




Рисунок 1 – семена злаковых (ячмень и пшеница) до прорастания и обработки нанокремнием



Рисунок 2 – пророщенные семена пшеницы в виде ростков без обработки и с обработкой нанокремнием

У ростков пшеницы (лат. *Triticum L.*) измерены длины, которые представлены выборками в таблице 1. Объем выборки: $n=50$.

Таблица 1 - Протокол измерений длин ростков пшеницы

Длины необработанных семян пшеницы, см	Длины обработанных семян пшеницы, см
Ростки	Ростки
12,50	8,30
9,50	9,20
19,10	12,30
3,70	9,90
4,30	11,60
0,00	11,20
5,70	10,60
8,00	10,30
5,80	11,40
5,90	10,10
19,60	9,60
7,50	12,00
10,50	11,80
12,80	13,00
17,60	12,80
6,50	11,00
19,90	11,70
8,20	13,40
19,50	12,00
7,30	12,50
17,40	10,00
7,20	14,00
6,40	13,90
11,10	14,70
22,30	12,30
4,00	12,10
5,40	13,00
24,60	11,40
18,40	11,30
8,40	12,30
7,60	12,90
4,00	12,00
5,80	13,00
10,00	12,70
4,50	12,60
21,50	12,40
15,50	10,50
19,40	11,60
15,60	12,00
26,20	11,90
17,30	12,10
19,50	10,10
18,10	11,70
14,30	11,20

22,00	12,80
22,00	10,90
4,70	11,10
8,50	13,70
9,20	14,10
13,10	13,00

Пусть выборка X – это длина пророщенных ростков пшеницы без применения нанокремния, а выборка Y – это длина пророщенных ростков пшеницы с применением нанокремния. На основе этих выборок необходимо составить интервальный ряд распределения.

Выборка X (таб.2):

- 1) определим размах вариации $R = x_{\max} - x_{\min} = 26,2 - 0,0 = 26,2$;
- 2) определим длину интервала, то есть шаг $h = R/k$, где k – количество интервалов; $h = 26,2/6 = 4,4$. Длина интервалов равна 6 в связи с тем, что объём выборки равен 50 .
- 3) Формируем интервалы $(x_i; x_{i+1})$, следовательно,
 $(x_1; x_2) = (x_{\min}; x_{\min} + h)$; $(x_2; x_3) = (x_2; x_2+h)$; $(x_3; x_4) = (x_3; x_3+h)$;
 $(x_4; x_5) = (x_4; x_4+h)$; $(x_5; x_6) = (x_5; x_5+h)$; $(x_6; x_7) = (x_6; x_6+h)$.

Таблица 2 – Интервальный ряд выборки X

№	$(X_i; X_{i+1})$	n_i	W_i	$X_{\text{сеп}}$	n_h
1	(0; 4,4)	5	0,1	2,2	5
2	(4,4; 8,8)	17	0,34	6,6	22
3	(8,8; 13,2)	8	0,16	11	30
4	(13,2; 17,6)	5	0,1	15,4	35
5	(17,6; 22)	10	0,2	19,8	45
6	(22; 26,4)	5	0,1	24,2	50

n_i – локальная частота, которая показывает сколько раз встретилась соответствующая варианта; W_i – относительная частота (частость появления i -ой варианты); $X_{\text{сеп}}$ – середина интервала; n_h – накопленная частота.

Выборка Y (таб. 3):

- 1) определим размах вариации $R = y_{\max} - y_{\min} = 14,7 - 8,3 = 6,4$;
- 2) определим длину интервала, то есть шаг $h = R/k$, где k – количество интервалов; $h = 6,4/6 = 1,1$. Длина интервалов равна 6 в связи с тем, что объём выборки равен 50 .

- 3) Формируем интервалы $(y_i; y_{i+1})$, следовательно,
 $(y_1; y_2) = (y_{\min}; y_{\min} + h)$; $(y_2; y_3) = (y_2; y_2+h)$; $(y_3; y_4) = (y_3; y_3+h)$;
 $(y_4; y_5) = (y_4; y_4+h)$; $(y_5; y_6) = (y_5; y_5+h)$; $(y_6; y_7) = (y_6; y_6+h)$.

Таблица 3 – Интервальный ряд выборки Y

№	$(y_i; y_{i+1})$	n_i	W_i	$y_{\text{сеп}}$	n_h
1	(8,3; 9,4)	2	0,04	8,85	2
2	(9,4; 10,5)	6	0,12	9,95	8
3	(10,5; 11,6)	10	0,2	11,05	18
4	(11,6; 12,7)	18	0,36	12,15	36
5	(12,7; 13,8)	10	0,2	13,25	46
6	(13,8; 14,9)	4	0,08	14,35	50

n_i – локальная частота, которая показывает сколько раз встретилась соответствующая варианта; W_i – относительная частота (частота появления i -ой варианты); $y_{\text{сеп}}$ – середина интервала; n_h – накопленная частота.

По представленным в таблице 2 и таблице 3 данным, вычислим выборочное среднее, выборочную дисперсию (исправленную выборочную дисперсию), выборочное среднее квадратическое отклонение (исправленное выборочное среднее квадратическое отклонение):

$$1) \bar{x}_B = \frac{1}{n} \sum_{i=1}^k \tilde{x}_i n_i \approx 12,1; \quad \bar{y}_B = \frac{1}{n} \sum_{i=1}^k \tilde{y}_i n_i \approx 11,9 \text{ - выборочное среднее}$$

$$2) D_B = \frac{1}{n} \sum_{i=1}^k \tilde{x}_i^2 n_i - (\bar{x}_B)^2 \approx 47,9; \quad D_B = \frac{1}{n} \sum_{i=1}^k \tilde{y}_i^2 n_i - (\bar{y}_B)^2 \approx 1,8 \text{ - выборочная дисперсия}$$

$$S_x^2 = \frac{n}{n-1} D_B \approx 48,9; \quad S_y^2 = \frac{n}{n-1} D_B \approx 1,8 \text{ - исправленная выборочная дисперсия}$$

$$3) \sigma = \sqrt{D_B} = \sqrt{47,9} \approx 6,9; \quad \sigma = \sqrt{D_B} = \sqrt{1,8} \approx 1,3 \text{ - выборочное среднее квадратическое отклонение}$$

$$4) S_x = \sqrt{S_x^2} = \sqrt{48,9} \approx 7,0; \quad S_y = \sqrt{S_y^2} = \sqrt{1,8} \approx 1,3 \text{ - исправленное выборочное среднее квадратическое отклонение}$$

На основе данных вычислений по выборке X и по выборке Y необходимо проверить гипотезу о равенстве двух средних генеральных совокупностей (независимые выборки). Однако данная гипотеза используется при нормальном законе. Поэтому нужно доказать, что X и Y распределены по нормальному закону, это можно сделать с помощью правила трёх сигм.

Для выборки X:

$P(|x - a| < 3\sigma) \approx 0,997$, практически все значения случайных величин $x \in N(a; \sigma)$ лежат в интервале $(a - 3\sigma; a + 3\sigma)$. [1,2]

Так как выборочное среднее $\bar{x}_B = 12,1$, следовательно, математическое ожидание $M(x) = a = \bar{x}_B = 12,1$; среднее квадратическое отклонение $\sigma_B \approx 6,9$ можем вычислить интервал: $(12,1 \pm 3 * 6,9) = (12,1 \pm 20,7) \Rightarrow (-8,6; 32,8)$. Все длины ростков пшеницы без обработки нанокремнием принадлежат интервалу $(-8,6; 32,8)$, следовательно, X распределена по нормальному закону.

Для выборки Y :

$P(|y - a| < 3\sigma) \approx 0,997$, практически все значения случайных величин $x \in N(a; \sigma)$ лежат в интервале $(a - 3\sigma; a + 3\sigma)$. [1,2]

Так как выборочное среднее $\bar{x}_B = 11,9$, следовательно, математическое ожидание $M(x) = a = \bar{x}_B = 11,9$; среднее квадратическое отклонение $\sigma_B \approx 1,4$ можем вычислить интервал: $(11,9 \pm 3 * 1,4) = (11,9 \pm 4,2) \Rightarrow (7,7; 16,1)$. Все длины ростков пшеницы с применением нанокремния принадлежат интервалу $(7,7; 16,1)$, следовательно, Y распределена по нормальному закону.

Генеральные совокупности X и Y распределены нормально, причём известны их исправленные дисперсии. По независимым выборкам X и Y , объёмы которых соответственно равны 50, найдены выборочные средние. Если учесть, что выборочные средние являются несмещёнными оценками генеральных средних, то нулевую гипотезу можно записать так $H_0: \bar{x}_G = \bar{y}_G$ (нанокремний незначительно повлияет на длины ростков пшеницы), при этом уровень значимости $\alpha = 0,01$. А конкурирующую гипотезу можно записать так $H_1: \bar{x}_G < \bar{y}_G$ (нанокремний значительно увеличит длину ростков пшеницы).

Необходимо вычислить наблюдаемое значение критерия по формуле:

$$T_{\text{набл}} = \frac{\bar{x}_B - \bar{y}_B}{\sqrt{\frac{s_x^2}{n_1} + \frac{s_y^2}{n_2}}}, \text{ где } S^2 \text{ – исправленная дисперсия, } n \text{ – объём выборки, } \bar{x}_B \text{ и } \bar{y}_B \text{ –}$$

выборочные средние, тогда $T_{\text{набл}} = \frac{12,1 - 11,9}{\sqrt{\frac{48,9}{50} + \frac{1,8}{50}}} \approx 0,2$.

Конкурирующая гипотеза имеет вид $H_1: \bar{x}_G < \bar{y}_G$, поэтому критическая область левосторонняя. По таблице функции Лапласа находим $T_{\text{кр.пр.}}$, используя неравенство $\Phi(T_{\text{кр.пр.}}) = 0,5 - \alpha = 0,5 - 0,01 = 0,49 \Rightarrow T_{\text{кр.пр.}} = 2,33$. Так как $T_{\text{кр.пр.}} = -T_{\text{кр.л.}}$, следовательно, $T_{\text{кр.л.}} = -2,33$.

Строим левостороннюю критическую область (рис.3):




Рисунок 3 – критическая область

У нас, наблюдаемое значение признака $T_{\text{набл}} = 0,2$ не принадлежит критической области, то есть интервалу $(-\infty; -2,33)$, $T_{\text{набл}} > T_{\text{кр}}$. Тем самым нет оснований отвергнуть нулевую гипотезу. То есть раствор нанокремния незначительно повлияет на длину ростков пшеницы.

Заключение. В результате исследования была принята нулевая гипотеза, анализ которой позволил заключить, что в сельском хозяйстве использование раствора нанокремния не приведёт к большой урожайности пшеницы.

Список литературы

- 1) Гмурман В. Е. Теория вероятностей и математическая статистика: учебное пособие для вузов / В. Е. Гмурман. – Москва : Высшая школа, 2003. – 281-303 С.
- 2) Теория вероятностей и математическая статистика : учебное пособие/ В. С. Мхитарян, Е. В. Астафьева, Ю. Н.Миронкина, Л. И. Трошкин; под ред. В. С. Мхитаряна . – 2-е изд., перера. и доп. – М.: Московский финансово-промышленный университет «Синергия», 2013. – 173 С.
- 3) Живетин В. Б. Высшая математика. Т.1. Лекции : учебное пособие / В. Б. Живетин . – Москва, 2005. - 535 С.
- 4) Рыжков И. Б. Основы научных исследований и изобретательства / И. Б. Рыжков. – учебное пособие. – 2-е изд., стер. – СПб. : «Лань», 2013. – 124 С.
- 5) Математическая статистика : практикум для студентов, обучающихся по направлениям бакалавриата / сост.: С. Я. Пономарёва, Е. Н. Соболева, Т. Р. Галлямова. – Ижевск, 2015.
- 6) Кузнецова О.В., Соболева Е.Н. Нужна ли математика будущему агроному? // Научное и кадровое обеспечение АПК для продовольственного импортозамещения : материалы Всероссийской научно-практической конференции, 16-19 февраля 2016 г. / Ижевская ГСХА. – Ижевск, 2016. – Т. 3. – С. 190-196.
- 7) Соболева Е.Н., Применение математики при решении прикладных задач в сельскохозяйственном вузе // Е.Н. Соболева / Инновационные технологии для реализации программы научно-технического развития сельского хозяйства: материалы Международной научно-практической конференции 13-16 февраля 2018 года, г. Ижевск. В 3 т. – Ижевск: ФГБОУ ВО Ижевская ГСХА, 2018. – Т. 3. – С. 264-269.