

Семинар 2

Статистически оценки на параметрите на разпределението

Това са задачи, решаването на които Вас ще задълбочи знания Ви по материала от лекция 2 - плътност на разпределение, функция на разпределение, интегрални граници и пр. Накрая на материала е дадено решението на задачите, но е добре Вие да се опитате да решите задачите самостоятелно.

Задача 2.1*. Дисперсията на една случайна величина X се дефинира като математическо очакване от квадрата на разликата между случайната величина и нейното математическо очакване.

$$D(X) = M\{[X - M(X)]^2\}$$

Докажете, че горният израз е еквивалентен на

$$D(X) = M(X^2) - M(X)^2. \quad (\text{II.1})$$

Задача 2.2*. Докажете, че формулата на квадрата на стандартното отклонение, S^2 , израз (2.4) от лекция 2,

$$S^2 = [\sum (X_k - \bar{X})^2] / (N-1) \quad (2.4)$$

може да се преобразува да е равен на:

$$S^2 = (\sum X_k^2 - N \bar{X}^2) / (N-1) \quad (2.4a)$$

Задача 2.3**. Докажете, че квадратът на стандартното отклонение, S^2 , е неизместена оценка на дисперсията, докато изразът (2.5) от лекция 2 е изместена оценка.

$$S^2 = [\sum (X_k - \bar{X})^2] / (N-1) \quad (2.4)$$

$$(\sum x_k^2 - N \bar{x}^2) / N \quad (2.5)$$

Задача 2.4. Програмата Excel има функции, които позволяват намиране на интеграл от плътността на разпределение на различни статистически разпределения, т.е. функцията на разпределение за дадена интегрална граница, както и обратната задача - да се намери интегралната граница при известен интеграл.

Намерете в Help-а описание на следните функции и го прочетете. Попълнете следната таблица. Наименовайте параметрите на функциите с имена от изучавания материал в лекции 1 и 2. Използвайте а) "интегрална граница"; б) "функция на разпределение"; в) "плътност на разпределение"; г) "степен свобода"; д) "едностранна/двустранна постановка"; е) "управляващ параметър".

Функция	Значение на параметрите
$Y = \text{NORMDIST}(x, \text{mean}, \text{stand_dev}, \text{cum})$	Y x mean stand_dev cum
$Y = \text{NORMINV}(\text{probab}, \text{mean}, \text{stand_dev})$	Y probab mean stand_dev
$Y = \text{NORMSINV}(\text{probab})$	Y probab
$Y = \text{CHIDIST}(x, \text{deg_freedom})$	Y x deg_freedom
$Y = \text{CHIINV}(\text{probab}, \text{deg_freedom})$	Y probab deg_freedom
$Y = \text{TDIST}(x, \text{deg_freedom}, \text{tails})$	Y x deg_freedom tails

Задача 2.5. Използвайте програмата Excel за да получите решението на задачи 1.10 и 1.11 от лекция 1.

Задача 1.10 (от лекция 1). За стандартното разпределение намерете от приложение 1 $F'(2.87)$ и $F(2.87)$, където $F(2.87)$ е интеграл в граници от $-\infty$ до 2.87, а $F'(2.87)$ - интеграл в граници от -2.87 до +2.87. Използвайте, че $F'(x) = 2F(x) - 1$.

Задача 1.11 (от лекция 1). За нормално разпределение с $\mu = 3.44$ и $\sigma = 0.39$ намерете от приложение 1 $F(4.56)$, където $F(4.56)$ е интеграл в граници от $-\infty$ до 4.56.

Задача 2.6. Използвайте програмата Excel за да получите решението на примери 2.2, 2.3 и 2.4 от лекция 2.

Пример 2.2. (от лекция 2)

а) Да се пресметне вероятността случайната величина χ^2_5 да заема стойности по-малки от 4.3.

б) Да се намери интервалът $(0, x)$, в който случайната величина χ^2_9 заема стойности с вероятност 0.90.

Пример 2.3 (от лекция 2). Да се намери вероятността отношението s^2/σ^2 да е в интервала $(0,1)$, където s е стандартното отклонение от десет измервания, а σ^2 е дисперсията на тяхното разпределение.

Пример 2.4 (от лекция 2). Да се намери вероятността t_9 -разпределена случайна величина да заема стойности:

а) по-малки от 2.8

б) в интервала $(2.8, 2.8)$

Задача 2.7. Подобни функции в програмата Excel има и за разпределението на Фишер. Намерете ги и ги разучете!

Решение на задачите

Задача 2.1*. Дисперсията на една случайна величина X се дефинира като математическо очакване от квадрата на разликата между случайната величина и нейното математическо очакване.

$$D(X) = M\{[X - M(X)]^2\}$$

Докажете, че горният израз е еквивалентен на

$$D(X) = M(X^2) - M(X)^2. \quad (\text{II.1})$$

Решение: Използваме свойствата 1-7 на дисперсията и математическото очакване от лекция 1. Вземаме под внимание, че $M(X)$ е число.

$$\begin{aligned} D(X) &= M\{[X - M(X)]^2\} = M\{X^2 - 2XM(X) + M(X)^2\} = \\ &= M(X^2) - M[2M(X)X] + M[M(X)^2] = \\ &= M(X^2) - 2M(X)M(X) + M(X)^2 = \\ &= M(X^2) - M(X)^2 \end{aligned}$$

Задача 2.2*. Докажете, че формулата на квадрата на стандартното отклонение, S^2 , израз (2.4) от лекция 2,

$$S^2 = [\Sigma (X_k - \bar{X})^2] / (N-1) \quad (2.4)$$

може да се преобразува да е равен на:

$$S^2 = (\Sigma X_k^2 - N \bar{X}^2) / (N-1) \quad (2.4a)$$

Решение: Преобразуваме числителя на (2.4) по следния начин:

$$\begin{aligned} \Sigma (X_k - \bar{X})^2 &= \Sigma (X_k^2 - 2 X_k \bar{X} + \bar{X}^2) = \Sigma X_k^2 - 2 \Sigma X_k \bar{X} + \Sigma \bar{X}^2 = \\ &= \Sigma X_k^2 - 2N \bar{X} \bar{X} + N \bar{X}^2 = \Sigma X_k^2 - N \bar{X}^2 \end{aligned}$$

Във времето, когато нямаше компютри, израз (2.4а) се препоръчваше за изчисляване на стандартното отклонение. В него има една сума от квадрати и едно намиране на средната стойност, докато в (2.4) освен тези действия има и изчисляване на N на брой разлики $X_k - \bar{X}$.

Сравнете израз (2.4а) с израз (II.1) от задача 1.

$$D(X) = M(X^2) - M(X)^2. \quad (\text{II.1})$$

$$S^2 = (\sum X_k^2 - N \bar{X}^2) / (N-1) \quad (2.4a)$$

Задача 2.3.** Докажете, че квадратът на стандартното отклонение, S^2 , е неизместена оценка на дисперсията, докато изразът (2.5) от лекция 2 е изместена оценка.

$$S^2 = [\sum (X_k - \bar{X})^2] / (N-1) \quad (2.4)$$

$$(\sum X_k^2 - N \bar{X}^2) / N \quad (2.5)$$

Решение: Една оценка е неизместена, ако математическото и очакване е равно на оценяваната величина, т.е. трябва математическото очакване на случайната величина S^2 да е равно на дисперсията на случайната величина X . Да не забравяме че дисперсията на отделните измервания е еднаква и равна на $D(X) = M\{[(X-M(X))]^2\}$. Трябва да докажем, че

$$M(S^2) = D(X) = M\{[(X-M(X))]^2\}.$$

В задача 2.2 доказахме, че

$$S^2 = (\sum X_k^2 - N \bar{X}^2) / (N-1)$$

Тогава

$$\begin{aligned} M[(N-1)S^2] &= M(\sum X_k^2 - N \bar{X}^2) = M(\sum X_k^2) - M(N \bar{X}^2) = \sum M(X_k^2) - NM(\bar{X}^2) = \\ &= NM(X^2) - NM(\bar{X}^2) \end{aligned}$$

Получихме, че

$$M[(N-1)S^2] = NM(X^2) - NM(\bar{X}^2) \quad (a)$$

Последният член в (a), $NM(\bar{X}^2)$, се развива по следният начин:

$$\begin{aligned} NM(\bar{X}^2) &= NM\left\{\left[\frac{\sum X_k}{N}\right]^2\right\} = N(1/N^2) M[(X_1 + X_2 + \dots + X_N)^2] = \\ &= (1/N)M(\sum X_k^2 + \sum X_k X_m) = (1/N)[M(\sum X_k^2) + M(\sum X_k X_m)] = \\ &= (1/N)[\sum M(X_k^2) + \sum \sum M(X_k X_m)] \end{aligned} \quad (b)$$

Отделните измервания са независими едно от друго и имат еднакво математическо очакване, затова последният член в скобите на (b) е равен на:

$$\sum \sum M(X_k X_m) = \sum \sum M(X_k) M(X_m) = \sum \sum M(X) M(X) = \sum \sum M(X)^2 = N(N-1)M(X)^2$$

Тук използвахме че в смесената сума има $N(N-1)$ членове.

Като отчетем, че първият член в скобите на (b) е равен на

$$\sum M(X_k^2) = \sum M(X^2) = NM(X^2)$$

за израза (b) получаваме

$$\begin{aligned} (1/N)[\sum M(X_k^2) + \sum \sum M(X_k X_m)] &= (1/N)[NM(X^2) + N(N-1)M(X)^2] = \\ &= M(X^2) + (N-1)M(X)^2 \end{aligned}$$

Т.е. изразът (b) е

$$NM(\bar{X}^2) = M(X^2) + (N-1)M(X)^2 \quad (c)$$

След като заместим израза (c) в (a) получаваме (двата израза (b) и (c) са едно и също нещо!)

$$\begin{aligned} &= NM(X^2) - NM(\bar{X}^2) = NM(X^2) - [M(X^2) + (N-1)M(X)^2] = \\ &= NM(X^2) - M(X^2) - (N-1)M(X)^2 = (N-1)M(X^2) - (N-1)M(X)^2 = \\ &= (N-1)[M(X^2) - M(X)^2] \end{aligned}$$

Т.е. получихме, че

$$M[(N-1)S^2] = (N-1)M[S^2] = (N-1)[M(X^2) - M(X)^2] \quad (d)$$

Ако разделим израз (d) на $(N-1)$ получаваме

$$M[S^2] = M(X^2) - M(X)^2 \quad (e)$$

В задача 2.1 получихме израз (II.1)

$$D(X) = M(X^2) - M(X)^2 \quad (II.1)$$

Приравнявайки изразите (e) и (II.1) получаваме окончателно

$$M[S^2] = D(X) \quad (f)$$

Ако бяхме използвали формула (2.5), в лявата страна на израза (f) щяхме да получим $N/(N-1)M[S^2]$, от което следва вместо израз (f) ще имаме

$$M[S^2] = [(N-1)/N]D(X)$$

Задача 2.4. Програмата Excel има функции, които позволяват намиране на интеграл от плътността на разпределение на различни статистически разпределения, т.е. функцията на разпределение за дадена интегрална граница, както и обратната задача - да се намери интегралната граница при известен интеграл. Намерете в Help-а описание на следните функции и го прочетете.

Попълнете следната таблица. Наименовайте параметрите на функциите с имена от изучавания материал в лекции 1 и 2. Използвайте а) "интегрална граница"; б) "функция на разпределение"; в) "плътност на разпределение"; г) "степени свобода"; д) "едностранна/двустранна постановка"; е) "управляващ параметър".

‡ Обърнете внимание, че част от функциите работят с нивото на значимост α (интеграл от плътността на разпределение от интегралната граница до безкрайност), а не с функцията на разпределение $F(X)$ (интеграл от плътността на разпределение от минус безкрайност до интегралната граница)! Връзката между тях е очевидно $F(X) = 1 - \alpha$.

Функция	Значение на параметрите
$Y = \text{NORMDIST}(x, \text{mean}, \text{stand_dev}, \text{cum})$	Y – функция или плътност на разпределение x – интегралната граница mean – математическо очакване stand_dev – стандартно отклонение cum – дали е функция или плътност на разпределение
$Y = \text{NORMINV}(\text{probab}, \text{mean}, \text{stand_dev})$	Y – интегралната граница probab – нивото на значимост mean – математическо очакване stand_dev – стандартно отклонение
$Y = \text{NORMSINV}(\text{probab})$	Y – интегралната граница probab – нивото на значимост
$Y = \text{CHIDIST}(x, \text{deg_freedom})$	Y – нивото на значимост x – интегралната граница deg_freedom – степени свобода
$Y = \text{CHIINV}(\text{probab}, \text{deg_freedom})$	Y – интегралната граница probab – нивото на значимост deg_freedom – степени свобода
$Y = \text{TDIST}(x, \text{deg_freedom}, \text{tails})$	Y – нивото на значимост x – интегралната граница deg_freedom – степени свобода tails – постановка на задамата: двустранна или едностранна

Отворете файла `seminar02_distributions.xls` и в таблицата "problem 2.4" сравнете прилагането на Excel функцията `CHIDIST()` с различни интегрални граници. Вижете, че има разлика от приложението на функцията `NORMDIST()`, която е изследвана в таблицата "normdist". Следващите три задачи също са решени в този файл, но се опитайте да ги решите сами, като използвате таблицата по-горе.

Задача 2.5. Използвайте програмата Excel за да получите решението на задачи 1.10 и 1.11 от лекция 1. Отворете файла `seminar02_distributions.xls` и разгледайте решенията в него.

Задача 1.10 (от лекция 1). За стандартното разпределение намерете от приложение 1 $F'(2.87)$ и $F(2.87)$, където $F(2.87)$ е интеграл в граници

от $-\infty$ до 2.87, а $F'(2.87)$ - интеграл в граници от -2.87 до +2.87. Използвайте, че $F'(x) = 2F(x) - 1$.

Решение: За $F(2.87)$ функцията е `NORMDIST(2.87,0,1,TRUE)`, която дава същия резултат, **0.99795**, като този, получен от [приложение 1](#). Същият резултат се получава и с функцията на стандартното разпределение, `NORMSDIST(2.87)`. Няма функция за двустранно постановка на въпроса, затова $F'(2.87)$ се намира като в решението на задача 1.10:

$$F'(2.87) = 2F(2.87) - 1 = 2 \times 0.99795 - 1 = 0.9959$$

Вместо константата `TRUE` може да се запише единица, а вместо `FALSE` - нула: в този случай функцията връща плътността на разпределение - вижте таблицата `NORMDIST` в същия файл.

Задача 1.11 (от лекция 1). За нормално разпределение с $\mu = 3.44$ и $\sigma = 0.39$ намерете от [приложение 1](#) $F(4.56)$, където $F(4.56)$ е интеграл в граници от $-\infty$ до 4.56.

Решение: За $F(4.56)$ функцията е `NORMDIST(4.56,3.44,0.39,TRUE)`, която дава същия резултат, **0.99796**, като този, получен от [приложение 1](#). Обърнете внимание, че числата се различават в петия знак, след десетичната запетая - програмата Excel изчислява интеграла на Лаплас с приближени числени методи - спомнете си, че той няма аналитично решение за произволни граници!

Задача 2.6. Използвайте програмата Excel за да получите решението на примери 2.2, 2.3 и 2.4 от лекция 2.

Пример 2.2 (от лекция 2).

а) Да се пресметне вероятността случайната величина χ^2_5 да заема стойности по-малки от 4.3.

Решение: Нивото на значимост се изчислява с `SNIDIST(4.5,5)` – получава се **0.48**. За функцията на разпределения (това е вероятността, която се търси) се получава, че е $1 - 0.48 = 0.52$, която е близка до 0.50, намерено от [приложение 2](#). Обърнете внимание, че в таблицата имаме само краен брой числа за интегралната граница (числото 4.5 го няма), докато програмата Excel изчислява функцията на разпределение с произволни интегрални граници: изчисленията не само са по-бързи от търсене в таблица, но и по-точни.

б) Да се намери интервалът $(0, \infty)$, в който случайната величина χ^2_9 заема стойности с вероятност 0.90.

Решение: Функцията е `SNINV(0.1,9)`, която дава близък резултат, **14.68**, до 14.7, намерено от [приложение 2](#). Обърнете внимание, че във функцията под името `probability` стои нивото на значимост 0.1, а не функцията на разпределение 0.9.

Пример 2.3 (от лекция 2). Да се намери вероятността отношението s^2/σ^2 да е в интервала $(0,1)$, където s е стандартното отклонение от десет измервания, а σ^2 е дисперсията на тяхното разпределение.

Решение: Нивото на значимост се изчислява с `SNIDIST(9,9)` и е **0.44**. Функцията е $1 - 0.44 = 0.56$, която е близка до намерената 0.50 от [приложение 2](#). Обърнете внимание, че разминаването в стойностите е повече от 10%, затова във времената, когато нямаше Excel при работа с интегрална граница, която я няма в таблицата можеше да се направи линейна интерполация.

Пример 2.4 (от лекция 2). Да се намери вероятността t_9 -разпределена случайна величина да заема стойности:

а) по-малки от 2.8

Решение: Нивото на значимост се изчислява с $\text{TDIST}(2.8, 9, 1)$ и е **0.01036**.
Функцията е $1 - 0.01036 = 0.98964$, която е близка до намерената 0.99 от [приложение 3](#). Обърнете внимание, че отново Excel функцията дава нивото на значимост, а не функцията на разпределение.

б) в интервала (2.8, 2.8)

Решение: Нивото на значимост се изчислява с $\text{TDIST}(2.8, 9, 2)$ и е **0.02071**.
Функцията е $1 - 0.02071 = 0.97929$, която е близка до намерената 0.98 от [приложение 3](#). Разликата с предишната точка е, че $\text{tails} = 2$, а не 1. Както се очакваше, поради симетричността на разпределението нивото на значимост е двойно по-голямо от това в т. а). Обърнете внимание, че отново Excel функцията дава нивото на значимост, а не функцията на разпределение.