

Курс «Статистика»

Л.И.Руденко

доцент, к.ф.-м.н., кафедра информационных систем в экономике

Тема 1. Введение.

Статистикой называется отрасль знаний, объединяющая принципы и методы работы с числовыми данными, характеризующими массовые явления. Статистика – это также отрасль практической деятельности, направленная на сбор, обработку и анализ статистических данных. Основными понятиями статистики являются:

- статистическая совокупность, или массовое явление. – множество однокачественных варьирующих явлений;
- единица совокупности – неделимый объект исследования, сохраняющий свойства изучаемого процесса;
- признак – характеристика или свойство единиц совокупности;
- статистический показатель – характеристика группы единиц или совокупности в целом;
- система статистических показателей – совокупности статистических показателей, отражающая объективные взаимосвязи характеристик и явлений;
- статистическая закономерность – закономерность изменения и развития массовых явлений, которая в массе явлений проявляется себя как необходимость, закон, а для каждой единицы связана со случайностью, индивидуальностью.

Предметом статистики является совокупность варьирующих явлений.

Цель статистического изучения – обработка и анализ данных о статистической совокупности. Статистический метод включает сбор данных (статистическое наблюдение), их обобщение, представление, анализ и интерпретацию.

По характеру решаемых задач различают два основных раздела статистических исследований: *описательную статистику* (обобщение и анализ статистических наблюдений) и *статистический вывод* (обобщение выборочных закономерностей на всю совокупность).

Тема 2. Описательная статистика. Статистические показатели

Статистическая совокупность состоит из единиц совокупности, которые обладают характерными свойствами – признаками. Признаки единиц совокупности могут быть следующими: по характеру выражения – *описательные* (атрибутивные) и *количественные*; по способу измерения – *первичные* (учитываемые) и *вторичные* (расчетные); по отношению к характеризуемому объекту – *прямые* (непосредственные) и *косвенные* (связанные с другими объектами); по характеру вариации – *альтернативные* (два значения), *дискретные* (конечное множество значений), *непрерывные* (непрерывно изменяющиеся); по отношению ко времени – *моментные* и *интервальные*.

Статистический показатель – характеристика группы единиц или совокупности в целом. Статистические показатели могут быть следующими: по содержанию – *показатели свойств конкретных объектов* (средний возраст работников предприятия, объем реализованной продукции, рождаемость) и *показатели статистических свойств* любых массовых явлений (средние показатели, показатели вариации, показатели связи признаков); по количественной оценке – *абсолютные* (отражают суммарное свойство объекта, измеряются в

натуральных единицах) и *относительные* показатели (получены путем сопоставления абсолютных и относительных показателей).

Основные группы относительных показателей: 1) относительные показатели *структурь объекта* – доли (измеряются в процентах, промилле); 2) относительные показатели *динамики* – темпы роста, темпы прироста (цепные и базисные); 3) относительные показатели *взаимосвязи* – коэффициенты корреляции, детерминации, эластичности; 4) относительные показатели *интенсивности*, например, урожайность, трудоемкость (выражаются в именованных относительных единицах); 5) показатели отношения фактических величин признака к нормативным, например, показатели выполнения норм выработки, расхода ресурсов.

Основные функции статистических показателей – информационная, прогностическая, оценочная, рекламная.

Тема 3. Средние величины

Различие между индивидуальными явлениями совокупности называется вариацией. **Средняя величина** – это обобщающая мера варьирующего признака, характеризующая всю совокупность в целом. В статистике используют различные виды средних, в том числе:

Средняя арифметическая

(x_i - значения признаков, n – количество):

$$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$$

$$\bar{x} = \frac{x_1 + x_n + x_2 + \dots + x_{n-1}}{n-1}$$

Средняя хронологическая

(x_i - значения моментных показателей, n –

количество моментов с равными интервалами):

Средняя квадратическая

(x_i - значения признаков, n – количество):

$$\bar{x}_{\text{кв}} = \sqrt{\frac{\sum_{i=1}^n x_i^2}{n}}$$

$$\bar{x}_{\text{квм}} = \sqrt[n]{x_1 \cdot \dots \cdot x_n}$$

Средняя геометрическая

(x_i - значения признаков, n – количество):

Средняя гармоническая

(x_i - значения признаков, n – количество):

$$\bar{x}_{\text{гарм}} = \frac{n}{\sum_{i=1}^n \frac{1}{x_i}}$$

Средняя арифметическая взвешенная

(x_i - значения признаков, f_i - веса):


$$\bar{x} = \frac{\sum_{i=1}^n x_i f_i}{\sum_{i=1}^n f_i}$$

Тема 4.. Представление статистических данных

Статистическая таблица – это система строк и столбцов, в которых в определенной последовательности и связи излагается статистическая информация. Различают *подлежащее* и *сказуемое* статистической таблицы. В подлежащем указывается характеризуемый объект (единицы совокупности, группы, совокупность в целом). В сказуемом дается характеристика объекта, обычно количественная. По характеру подлежащего таблицы делятся на *простые, групповые, комбинационные*. Подлежащим простой таблицы является перечень всех единиц совокупности, территориальный или хронологический ряд. В

групповой таблице подлежащим является группировка по одному признаку, в комбинационной – по двум и более признакам. Заголовки приводятся без сокращений, с указанием единиц измерения. Итоговая строка, как правило, завершает таблицу, но иногда может быть первой. Цифровые данные записываются с одинаковой точностью. В таблице не должно быть пустых клеток.

Наглядной формой представления статистических данных являются графики: *диаграммы, картограммы и картодиаграммы*. Наиболее распространены диаграммы, в том числе, *линейные, радиальные, точечные, плоскостные, объемные, фигулярные* диаграммы .



Тема 5. Вариационный ряд

Вариационный ряд, или ряд распределения, характеризует состав, структуру совокупности по некоторому признаку. Элементами ряда распределения являются значения признака x_i и частоты f_i .

Частотные характеристики

Индивидуальные значения признака $\{x_i\}_{i=1,\dots,n}$, n – количество наблюдений.

Число интервалов (групп) определяют по формуле: $k=1+3,32 \lg n = 1+1,44 \ln n$ (формула Штюргесса).

Длина интервала (шаг): $h=(x_{max} - x_{min})/k$. Середина интервала: x_j . Частота: f_j ;

частота: $w_j = \frac{f_j}{n}$; накопленная частота $\hat{f}_j = \sum_{\alpha=1}^j f_{\alpha}$. Плотность: абсолютная –


$f'_j = \frac{f_j}{h}$; относительная – $w'_j = \frac{f_j}{n}$.

Графическое отображение:


-гистограмма (столбцовая диаграмма, на которой по оси абсцисс расположены интервалы значений признака, по оси ординат – интервальные частоты);
-полигон (ломаная с вершинами $(x_j; f_j)$); кумулята (ломаная с вершинами

$(x'_j; \sum_{\alpha=1}^j f_{\alpha}))$; огива (ломаная с вершинами $(x_j; \sum_{\alpha=j}^k f_{\alpha})$).


Гистограмма



Полигон частот



Кумулята и огива



Структурные характеристики вариационного ряда

Среднее арифметическое значение $\bar{x} = \frac{\sum_{i=1}^n x_i f_i}{\sum_{i=1}^n f_i}$

Медиана (величина признака, делящая совокупность значений на две равные части):

$$M_e = x_{Me} + \left(\frac{\sum_{j=1}^k f_j}{2} - \hat{f}_{Me-1} \right) * \frac{h}{f_{Me}}, \quad \text{где } x_{Me} - \text{левая граница медианного интервала,}$$

f_{Me}, \hat{f}_{Me-1} -- соответственно частота медианного и накопленная частота предмедианного интервалов. В медианном интервале накопленная частота больше или равна половине общего числа единиц совокупности.

Мода – величина признака, которая встречается в вариационном ряду наиболее часто. В модальном интервале частота максимальна.

Точечная мода

$$M_o = x_{Mo} + \frac{f_{Mo} - f_{Mo-1}}{(f_{Mo} - f_{Mo-1}) + (f_{Mo} - f_{Mo+1})} \cdot h, \quad \text{где } f_{Mo}, f_{Mo-1}, f_{Mo+1} \quad \text{-- частоты модального,}$$

предмодального и постмодального интервалов.

Характеристики вариации	для сгруппированных данных	для несгруппированных данных
<i>Среднее арифметическое значение</i>	$\bar{x} = \frac{\sum_{j=1}^k x'_j f_j}{\sum_{j=1}^k f_j}$	$\bar{x} = \frac{1}{n} \sum_{i=1}^n x_i$
<i>Размах вариации</i>		$R = X_{\max} - X_{\min}$
<i>Средний модуль отклонений</i> (среднее линейное отклонение)	$a = \frac{\sum_{j=1}^k x'_j - \bar{x} f_j}{\sum_{j=1}^k f_j}$	$a = \frac{1}{n} \sum_{i=1}^n x_i - \bar{x} $
<i>Среднее квадратическое отклонение</i>	$s = \sqrt{\frac{\sum_{j=1}^k (x'_j - \bar{x})^2 f_j}{\sum_{j=1}^k f_j}}$	$s = \sqrt{\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n}}$

<i>Выборочная дисперсия</i>	$s^2 = \frac{\sum_{j=1}^k (x'_j - \bar{x})^2 f_j}{\sum_{j=1}^k f_j}$	$s^2 = \frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n}$
<i>Относительный размах вариации (коэффициент осцилляции)</i>	$\rho = \frac{R}{\bar{x}}$	$\rho = \frac{R}{\bar{x}}$
<i>Относительное отклонение по модулю (линейный коэффициент вариации)</i>	$m = \frac{a}{\bar{x}}$	$m = \frac{a}{\bar{x}}$
<i>Коэффициент вариации (квадратичный)</i>	$v = \frac{s}{\bar{x}}$	$v = \frac{s}{\bar{x}}$

Моменты распределения


<i>Центральные моменты</i>	<i>для сгруппированных данных</i>	<i>для несгруппированных данных</i>
первый m_1	$\frac{\sum_{j=1}^k (x'_j - \bar{x}) f_j}{\sum_{j=1}^k f_j} = 0$	$\frac{\sum_{i=1}^n (x_i - \bar{x})}{n} = 0$
второй m_2	$\frac{\sum_{j=1}^k (x'_j - \bar{x})^2 f_j}{\sum_{j=1}^k f_j} = s^2$	$\frac{\sum_{i=1}^n (x_i - \bar{x})^2}{n} = s^2$
третий m_3	$\frac{\sum_{j=1}^k (x'_j - \bar{x})^3 f_j}{\sum_{j=1}^k f_j}$	$\frac{\sum_{i=1}^n (x_i - \bar{x})^3}{n}$
четвертый m_4	$\frac{\sum_{j=1}^k (x'_j - \bar{x})^4 f_j}{\sum_{j=1}^k f_j}$	$s^4 = \frac{\sum_{i=1}^n (x_i - \bar{x})^4}{n}$
<i>Показатель асимметрии</i>	$As = \frac{m_3}{s^3}$	$As = \frac{m_3}{s^3}$
<i>Показатель асимметрии Пирсона</i>	$As_H = \frac{\bar{x} - Mo}{s}$	$As_H = \frac{\bar{x} - Mo}{s}$
<i>Показатель эксцесса</i>	$Ex = \frac{m_4}{s^4} - 3$	$Ex = \frac{m_4}{s^4} - 3$

Нормальное распределение



$$\phi(t) = \frac{1}{\sqrt{2\pi}\sigma} e^{-\frac{(t-\mu)^2}{2\sigma^2}};$$

функция распределения



$$F(x) = \int_{-\infty}^{+\infty} \phi(t) dt.$$

Тема 6. Группировка по признакам

Группировка – это разбиение совокупности на группы по какому-либо признаку. Группировка производится на основе *группировочного признака* и его значений, определяющих *интервалы группировки*. Группировка по одному признаку называется *простой*, по нескольким признакам – *сложной, комбинационной..* Виды группировок: 1) типологическая группировка служит для выявления социально-экономических типов; 2) структурная группировка характеризует структуру совокупности по какому-либо признаку; 3) аналитическая (факторная) группировка характеризует взаимосвязь между двумя и более признаками. Примеры представления группировок таблицами:

а) простые структурные группировки;

Количество членов домохозяйства	Количество домохозяйств
2	4
3	10
4	6
Всего	20

Общий денежный доход, д.е.	Количество домохозяйств
Менее 200	3
200-400	10
400-600	5
600 и более	2
Всего	20

б) комбинационная группировка;

Количество членов домохозяйств	Общий денежный доход домохозяйства, д.е.					Всего
	Менее 200	200-400	400-600	600 и более		
2	2	2	0	0	4	
3	1	5	3	1	10	
4	0	3	2	1	6	
Всего	3	10	5	2	20	

в) аналитическая группировка.

Количество членов домохозяйс- тва	Количество домохозяйс- тв	Суммарное количество членов домохозяйств	Доход за месяц, д.е.		
			Общий денежный	В среднем	
				на одно домохозяйс- тво	на одного члена домохозяйства
2	4	8	1096	274,0	137,0
3	10	30	3752	375,2	125,1
4	6	24	2652	442,0	110,5
По совокупнос- ти в целом	20	62	7500	375,0	121,0

Многомерная группировка

Многомерная группировка (*классификация*) основана на использовании меры сходства между объектами. Выделяют три типа мер сходства: 1) коэффициенты подобия, используемые для измерения степени близости между парами объектов, признаки которых принимают значения 0 и 1 (бинарные);

2) коэффициенты связи, в частности, коэффициенты корреляции (линейной корреляции для количественных признаков, ранговой корреляции для атрибутивных признаков); 3) функции расстояния:

а) хеммингово расстояние $d_y = \sum_{k=1}^m |x_{ik} - x_{jk}|$ для бинарных признаков; б) евклидово

расстояние $d_y = \sqrt{\sum_{k=1}^m (x_{ik} - x_{jk})^2}$ для количественных признаков и другие. Для

выполнения многомерных классификаций применяют: метод дендритов, метод шаров, метод многомерной средней, метод корреляционных плеяд. Одной из распространенных процедур классификации является основанная на вычислении расстояний *процедура кластерного анализа*. Эта процедура предполагает последовательное оценивание расстояний между объектами и группами и объединение в группы (классы) объектов с наименьшими расстояниями.

Тема 7. Статистический вывод 1. Выборочный метод

Метод статистического вывода позволяет по данным выборки делать заключения о свойствах генеральной совокупности – при условии репрезентативности выборки.

Выборочные характеристики: среднее значение, выборочная дисперсия, доля – являются *оценками параметров генеральной совокупности*: генеральная средняя, генеральная дисперсия, генеральная доля и др. Оценки могут быть состоятельными, несмешенными, эффективными. Выборочные характеристики позволяют сделать предположение о характере теоретического распределения.

Метод статистического вывода предполагает формулировку *статистических гипотез* и их проверку на основе *статистических критериев*.

Тема 8. Статистические гипотезы

Статистическая гипотеза – это некоторое допущение о свойствах генеральной совокупности, которое можно проверить по данным выборочного исследования. Гипотеза, которую следует проверить (*нулевая гипотеза*, H_0) формулируется как отсутствие расхождений между параметром генеральной совокупности А и его выборочной оценкой a ($H_0: A=a$), *альтернативная гипотеза*, противоположная нулевой, может иметь вид: $H_1: A>a$; $H_1: A<a$; $H_1: A\neq a$. При проверке гипотезы возможны две ошибки: *ошибка первого рода* – отвергнуть правильную гипотезу; *ошибка второго рода* – принять неправильную гипотезу. Вероятность α ошибки первого рода называют уровнем значимости. *Статистическим критерием* называют случайную величину K с известным законом распределения. В качестве статистических критериев используются стандартное нормальное распределение, распределения Стьюдента, χ^2 , Фишера. *Критической областью* называют совокупность значений критерия, при которой гипотезу отвергают. Точки, отделяющие критическую область от области принятия гипотезы, называют *критическими точками*. Основной принцип проверки статистических гипотез: если наблюдаемое значение критерия принадлежит критической области – гипотезу отвергают, если наблюдаемое значение критерия принадлежит области принятия гипотезы – гипотезу принимают.

Тема 9. Репрезентативность выборки

Пусть $\{x_i\}$ – выборка размера n , для которой вычислены среднее значение \bar{x} , выборочная дисперсия s^2 , исправленная выборочная дисперсия S^2 . Пусть γ – доверительная вероятность (надежность), $\alpha=1-\gamma$ – уровень значимости.

1) *Ошибка выборки* (точность оценки) для среднего значения.

При известной генеральной дисперсии σ^2 : доверительное число $t = \frac{\sigma}{\sqrt{n}}$

определяется по таблице функции Лапласа из соотношения $\Phi(t) = \frac{\gamma}{2}$.

При неизвестной генеральной дисперсии: $\Delta_x = t \frac{S}{\sqrt{n}}$ (для больших выборок).

$\Delta_x = t \frac{S}{\sqrt{n-1}}$ (для малых выборок); доверительное число t определяется по таблице распределения Стьюдента: $t = t_{(1-\gamma, n-1)}$.

Доверительный интервал: $(\bar{x} - \Delta_x; \bar{x} + \Delta_x)$ с надежностью γ покрывает генеральную среднюю.

2) *Ошибка доли* $\Delta_p = t \sqrt{\frac{p(1-p)}{n}}$; *доверительный интервал для доли* $(p - \Delta_p; p + \Delta_p)$;

доверительное число t определяется по таблице распределения Стьюдента: $t = t_{(1-\gamma, n-1)}$.

3) *Ошибка дисперсии* $\Delta_s = Sq$, *доверительный интервал* $(S - \Delta_s; S + \Delta_s)$; q – табличное значение при заданных n и γ (см. табл. приложения 4 [1]).

Тема 10. Проверка гипотезы о нормальном законе распределения

Используются следующие критерии согласия:

а) критерий САО (средних абсолютных отклонений): $\left| \frac{\sum |x_i - \bar{x}|}{nS} - 0,7979 \right| < \frac{0,4}{\sqrt{n}}$;

б) *R/S-критерий*: $(R/S)_u < R/S < (R/S)_v$, где R/S – отношение размаха вариации к среднеквадратическому отклонению, $(R/S)_u$, $(R/S)_v$ – его табличные значения при заданном γ .

в) χ^2 -критерий: $\chi^2 < \chi^2(1-\gamma; n-1)$, где $\chi^2(1-\gamma; n-1)$ – табличное значение (критическая точка); $\chi^2 = \sum \frac{(f_j - z_j)^2}{z_j}$ – наблюдаемое значение, вычисленное для выборочных f_j и теоретических частот z_j .

Тема 11. Основы дисперсионного анализа

Модель дисперсионного анализа используется для изучения влияния качественного фактора F на изучаемый признак X . При этом сравниваются «факторная дисперсия», порожденная влиянием фактора и «остаточная дисперсия», обусловленная случайными причинами.

Пусть фактор F изменяется на p уровнях, x_{ij} – значения признака X в i -м испытании на j -м уровне фактора ($i = 1, q$; $j = 1, p$; $pq = n$). Вводятся следующие суммы квадратов отклонений:

$$SS_{общ} = \sum_{j=1}^p \sum_{i=1}^q (x_{ij} - \bar{x})^2; \quad SS_{факт} = q \sum_{j=1}^p (\bar{x}_j - \bar{x})^2; \quad SS_{ост} = \sum_{j=1}^p \sum_{i=1}^q (x_{ij} - \bar{x}_j)^2 \quad \text{и}$$

соответствующие дисперсии:

$$s_{общ}^2 = \frac{SS_{общ}}{pq-1} \text{ – общая;} \quad s_{факт}^2 = \frac{SS_{факт}}{p-1} \text{ – факторная;} \quad s_{ост}^2 = \frac{SS_{ост}}{p(q-1)} \text{ – остаточная}$$

дисперсии.

F-отношение $F = \frac{s_{\text{факт}}^2}{s_{\text{ообр}}^2}$ имеет распределение Фишера со степенями свободы $p-1$ и $p(q-1)=n-p$. Гипотеза H_0 , состоящая в том, что фактор F не оказывает влияния принимается, если $F \geq F_{(\alpha, p-1, n-p)}$, где $F_{(\alpha, p-1, n-p)}$ – критическая точка (процентная точка распределения Фишера).

Тема 12. Корреляционный и регрессионный анализ Задачи корреляционно-регрессионного анализа и моделирования

Различают два типа связей явлений: *функциональную* и *статистическую*. При функциональной связи величина y однозначно зависит от величины x и ни от чего более. При статистической связи разным значениям одной величины соответствуют разные распределения значений другой величины. Важнейший случай статистической связи – *корреляционная связь*, при которой разным значениям одной величины соответствуют различные *средние* значения другой величины. Предполагается, что результаты и факторы являются количественными признаками.

Основные задачи корреляционно-регрессионного анализа: 1) вычисление параметров уравнения связи (*уравнения регрессии*) средних величин результативного признака с значениями одного или нескольких факторов; 2) оценка тесноты связи двух или более признаков между собой. Эти задачи решаются и исследуются на основе двух моделей: аналитической группировки и регрессионного анализа.

Модель аналитической группировки предполагает, что признак-фактор x изменяется на p уровнях (разбить на p групп), а индивидуальные значения результата $\{y_i\}_N$ преобразованы в интервальный ряд $\{\bar{y}_l, f_l\}$, где f_l – частота в l -й группе по значению результата, \bar{y}_l – частота в j -й группе по значению фактора, f_{jl} – частота результата l -й группы при значении фактора из j -й группы. После

вычисления средних значений результата в j -й группе $\bar{y}_j = \frac{\sum y_l f_{jl}}{\sum f_{jl}}$ и общей средней

$\bar{y} = \frac{\sum y_j f_j}{\sum f_j}$ вычисляются общая дисперсия, межгрупповая (факторная) дисперсия,

внутригрупповые дисперсии и средняя из межгрупповых (остаточная) дисперсия:

$$s_{\text{общ}}^2 = \frac{\sum (y_l - \bar{y})^2 f_l}{\sum f_l}; s_{\text{факт}}^2 = \frac{\sum (\bar{y}_j - \bar{y})^2}{\sum f_j}; s_j^2 = \frac{\sum (y_l^* - \bar{y}_j)^2 f_{jl}}{\sum f_{jl}}; s_{\text{ообр}}^2 = \frac{\sum s_j^2 f_j}{\sum f_j}.$$

Теснота связи результативного признака y с признаком-фактором x оценивается

величинами коэффициента детерминации $\eta^2 = \frac{s_{\text{факт}}^2}{s_{\text{общ}}^2}$ и эмпирического

корреляционного отношения $\eta = \sqrt{\frac{s_{\text{факт}}^2}{s_{\text{общ}}^2}}$. Последняя величина принадлежит

интервалу $[0,1]$: чем ближе к 1, тем теснее связь.

Тема 13.. Парная линейная корреляция


Уравнение парной линейной корреляционной связи называется *уравнением парной регрессии* и имеет вид: $\hat{y} = a + bx + \varepsilon$, где \hat{y} - среднее значение результативного признака, вычисляемое по уравнению связи, a - свободный член

$$\begin{cases} na + b \sum_{i=1}^n x_i = \sum_{i=1}^n y_i; \\ a \sum_{i=1}^n x_i + b \sum_{i=1}^n (x_i)^2 = \sum_{i=1}^n x_i y_i; \end{cases} \Rightarrow$$

уравнения, b - коэффициент регрессии, ε - ошибка. Параметры уравнения a, b определяются на основе метода наименьших квадратов (МНК) из условия минимизации суммы квадратов отклонений $\sum_{i=1}^n (y_i - (a + bx_i))^2 \rightarrow \min$, которое позволяет

получить систему нормальных уравнений и найти a, b :

$$a = \bar{y} - b\bar{x}; b = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sum_{i=1}^n (x_i - \bar{x})^2}.$$



Графически линия регрессии есть прямая, проходящая через «облако точек» -- эмпирических данных.

Коэффициент регрессии b имеет смысл показателя *силы связи* между вариацией факторного признака и вариацией результата: он измеряет среднее по совокупности отклонение y от его средней величины при отклонении признака x от своей средней величины на единицу измерения. Теснота связи измеряется

коэффициентом детерминации $\eta^2 = \frac{1}{n} \sum_{i=1}^n (\hat{y}_i - \bar{y})^2$ и корреляционным отношением

$\eta = \sqrt{\eta^2}$. Кроме того при линейной форме связи применяется стандартизованный коэффициент регрессии, или *коэффициент корреляции* $r = \frac{\sum_{i=1}^n (x_i - \bar{x})(y_i - \bar{y})}{\sqrt{\sum_{i=1}^n (x_i - \bar{x})^2 \sum_{i=1}^n (y_i - \bar{y})^2}}$.

При этом $|r| \leq 1$. Знак коэффициента определяет направление связи (при положительном r связь прямая).

Тема 14. Оценка надежности

1) Для коэффициента регрессии вычисляется средняя ошибка $s_b = \sqrt{\frac{\sum (y_i - \hat{y}_i)^2}{(n-2) \sum (x_i - \bar{x})^2}}$ и доверительное число $t = \frac{|b|}{s_b}$. Если $t > t_{(\alpha, n-2)}$, где $t_{(\alpha, n-2)}$ -- процентная точка распределения Стьюдента, то коэффициент b является значимым (надежным) с вероятностью $1-\alpha$.

2) Для уравнения регрессии вычисляется отношение $F = \frac{\frac{1}{n-2} \sum (y_i - \hat{y}_i)^2}{\frac{1}{n-2} \sum (y_i - \bar{y})^2}$ и

критическое значение $F_{(n-1, n-2, \alpha)}$ по таблице распределения Фишера. Если $F > F_{(n-1, n-2, \alpha)}$, то уравнение описывает линейную связь с надежностью $1-\alpha$.

3) Для коэффициента корреляции вычисляется средняя ошибка $s_r = \sqrt{\frac{1-r^2}{n-2}}$ и доверительное число $t = \frac{|r|}{s_r}$. Если $t > t_{(\alpha/2, n-2)}$, то коэффициент корреляции значим с вероятностью $1-\alpha$.

Наряду с уравнением линейной регрессии для описания связи признаков используются следующие нелинейные модели, параметры которых также оцениваются на основе метода наименьших квадратов:

1) параболическая корреляция (регрессия) $\hat{y} = a + bx + cx^2$;

2) кубическая корреляция (регрессия) $\hat{y} = a + bx + cx^2 + dx^3$;

3) гиперболическая корреляция (регрессия) $\hat{y} = a + \frac{b}{x}$,

а также другие модели, линейные по параметрам. Выбор оптимальной формы связи предполагает последовательной построение и оценку значимости различных уравнений связи, из которых предпочтение отдается тому, которое обеспечивает

наименьшую остаточную дисперсию $s_{ocm}^2 = \frac{1}{n-2} \sum (y_i - \hat{y}_i)^2$.

Тема 15. Множественный корреляционный анализ

Если требуется изучить влияние на вариацию результативного признака у факторов x_1, \dots, x_p , то строится модель множественного линейного корреляционного анализа: $\hat{y} = b_0 + \sum_{j=1}^p b_j x_j + \varepsilon$. Обозначим

$$X = \begin{pmatrix} 1 & x_{11} & \dots & x_{1p} \\ \dots & \dots & & \dots \\ 1 & x_{n1} & \dots & x_{np} \\ \dots & \dots & & \dots \\ 1 & x_{n1} & \dots & x_{np} \end{pmatrix}; X' = \begin{pmatrix} 1 & \dots & 1 & \dots & 1 \\ x_{11} & \dots & x_{11} & \dots & x_{n1} \\ \dots & \dots & \dots & \dots & \dots \\ x_{1p} & \dots & x_{1p} & \dots & x_{np} \end{pmatrix}; B = \begin{pmatrix} b_0 \\ b_1 \\ \dots \\ b_p \end{pmatrix}; Y = \begin{pmatrix} y_1 \\ \dots \\ y_n \end{pmatrix}.$$

можно представить систему нормальных уравнений (метода наименьших квадратов) для определения параметров уравнения регрессии в матричном виде: $(X' X)B = X' Y$, откуда $B = (X' X)^{-1} X' Y$. Оценка надежности коэффициентов

регрессии b_j основана на вычислении величин $s_{b_j} = \sqrt{\frac{\sum (y_i - \hat{y}_i)^2 c_{jj}}{n-2}}$, $t = \frac{|b_j|}{s_{b_j}}$ (где c_{jj} -- диагональные элементы матрицы $X' X$) и сравнении t с критическим значением $t_{(\alpha/2, n-p-1)}$.

Тема 16. Связь атрибутивных признаков

В случае изучения связи неколичественных (атрибутивных) признаков используются следующие меры связи:

1) коэффициент корреляции рангов Спирмена $r_s = \frac{\sum (p_{xi} - \bar{p}_x)(p_{yi} - \bar{p}_y)}{\sqrt{\sum (p_{xi} - \bar{p}_x)^2 \sum (p_{yi} - \bar{p}_y)^2}}$,

где p_{xi}, p_{yi} -- ранги признаков, т.е. их порядковые номера. Если обозначить $d_i^2 = (p_{xi} - p_{yi})^2$, то , с учетом того, что

$$\bar{p}_x = \bar{p}_y = \frac{n+1}{2}, \sum (p_{xi} - \bar{p}_x)^2 = \sum (p_{yi} - \bar{p}_y)^2 = \frac{n^3 - n}{12}, \text{ получим: } r_s = 1 - \frac{6 \sum d_i^2}{n^3 - n}.$$

2) коэффициент ранговой корреляции Кендалла $r_k = \frac{4R}{n(n-1)}$, где $R = \sum_{j=1}^{n-1} R_j$, R_j --

количество рангов, больших, чем $p_{yj}, j = \overline{1, n-1}$,

а также коэффициент ассоциации (Пирсона) и коэффициент контингенции (Кендалла).

Тем 17. Статистическое изучение динамики. Динамический ряд

Динамический ряд – это размещенные в хронологической последовательности значения некоторого статистического показателя. В моментном динамическом ряду уровни показателя y_t фиксируют состояние явления на некоторые моменты времени t , в интервальном ряду – за некоторые промежутки. С течением времени значения уровней y_t варьируют. Если эта вариация в среднем монотонна, то говорят о *тенденции* (роста, снижения). Но в отдельные периоды уровни отклоняются от основной тенденции – испытывают *колебания*. Изучение тенденции и ее уравнения (тренда) и колеблемости – главные задачи динамического анализа.

Показатели тенденции динамики:

1) *абсолютное изменение* (абсолютный рост) – цепное $\Delta_t = y_t - y_{t-1}$, базисное $\Delta_{t0} = y_t - y_0$;

2) *тепп* изменения (темпер роста) – цепной $k_t = \frac{y_t}{y_{t-1}}$, базисный $k_{t0} = \frac{y_t}{y_0}$; 3)

ускорение (только цепное) $\Delta'_t = \Delta_t - \Delta_{t-1}$.

Средние показатели динамики:

1) *средний уровень* – для интервального ряда $\bar{y} = \frac{\sum_{t=1}^n y_t}{n}$; для моментного ряда

$$\bar{y} = \left(\frac{y_1 + y_n}{2} + \sum_{t=2}^{n-1} y_t \right) / (n-1); \quad 2) \quad \text{среднее абсолютное изменение}$$

$$(рост) \bar{\Delta} = \frac{\sum_{t=1}^n \Delta_t}{n} = \frac{y_n - y_0}{n};$$


$$3) \text{средний темп изменений} \bar{k} = \sqrt[n]{\prod_{t=1}^n k_t} = \sqrt[n]{\frac{y_n}{y_0}}.$$

Тренд (трендовоое уравнение) есть уравнение тенденции $y_t = f(t)$. При относительно стабильных приростах используют **линейный тренд** $\hat{y}_t = a + bt$, при при стабильных темпах прироста – показательную функцию $\hat{y}_t = ak^t$. Расчет

$$\left\{ \begin{array}{l} na + b \sum_{t=1}^n t = \sum_{t=1}^n y; \\ a \sum_{t=1}^n xt + b \sum_{t=1}^n (xt)^2 = \sum_{t=1}^n ty; \end{array} \right. \Rightarrow \text{параметров производится на основе метода наименьших квадратов из системы нормальных уравнений:}$$

(при переносе начала отсчета $t=0$ в середину ряда)

$$a = \bar{y}; b = \frac{\sum_{t=1}^n yt}{\sum_{t=1}^n t^2}.$$



Вычисленное по уравнению тренда значение y называется **точечным прогнозом**. Ошибка прогноза рассчитывается по формуле

$$s_p = s \sqrt{\frac{n+1}{n} + \frac{3(n+2v-1)}{n(n^2-1)}}, \text{ где } s_{ocm}^2 = \frac{1}{n-2} \sum_{i=1}^n (y_i - \hat{y}_i)^2, v - \text{период прогноза.}$$


Показатели колеблемости:

среднее абсолютное отклонение $a(t) = \frac{\sum |y_i - \hat{y}_i|}{n-p}$, (p – число параметров в уравнении тренда);

$$\text{среднее квадратическое отклонение } s(t) = \sqrt{\frac{\sum (y_i - \hat{y}_i)^2}{n-p}};$$

амплитуда колебаний $R(t) = y_{\max} - y_{\min}$;

коэффициент колеблемости $v(t) = \frac{s(t)}{y}$. Типы колеблемости:



1) пилообразная (маятниковая); 2) циклическая; 3) случайная (хаотичная).

Индексы

Индекс – это показатель сравнения двух состояний одного и того же явления. Индекс включает два вида данных – текущие(1) и базисные(0). Индексы выполняют две функции: *синтетическую* – это обобщающая характеристика изменения явления; *аналитическую* – изучение влияния отдельных факторов.

Индексы делятся на *динамические* (характеризуют изменение во времени), *территориальные* (изменение явления в пространстве, по регионам), *межгрупповые* (характеризуют отклонение от стандарта или среднего уровня). По степени агрегированности информации индексы делят на *индивидуальные* (i) и

сводные (I). Система обозначений индексируемых величин: p – цена, q – количество, c – себестоимость, t – трудоемкость.

Индивидуальный индекс динамики цен $i_p = \frac{P_1}{P_0}$. Сводный индекс является средним из них. Для его построения необходимо условие созмеримости цен на разнородные товары, поэтому используется вес – удельный вес товара в общем объеме в базисном периоде: $d_0 = \frac{q_0 p_0}{\sum q_0 p_0}$. Тогда сводный индекс $I_p = \frac{\sum i_p d_0}{\sum d_0} = \frac{\sum q_0 p_1}{\sum q_0 p_0}$ (индекс Ласпейреса). Если строить веса по отчетному периоду, то получают индекс $I_p = \frac{\sum q_1 p_1}{\sum q_1 p_0}$ (индекс Пааше).

Агрегатные индексы

Индексы, представленные в виде суммы произведений (агрегатов), называют *агрегатными*. Приведенные сводные индексы цен – агрегатные. Аналогично можно построить сводный индекс физического объема (количества): $I_q = \frac{\sum p_0 q_1}{\sum p_0 q_0}$ (в форме Ласпейреса) или $I_q = \frac{\sum p_1 q_1}{\sum p_1 q_0}$ (в форме Пааше). В агрегатных индексах признаки различают как *индексируемые* и *весовые*. Так, в I_p индексируемый признак p , весовой – q . Значение индексируемого признака меняется: отчетное значение сопоставляется с базисным.

Агрегат в целом $\sum pq$ (товарооборот) оценивается общим индексом товарооборота:

$$I_{pq} = \frac{\sum p_1 q_1}{\sum p_0 q_0}.$$

Если индексы рассматриваются в системе, то должна выполняться взаимосвязь между ними, например, $I_{pq} = I_p I_q$. Эта связь обеспечивается, только если индексы строятся с весами *разных* периодов (один с базисным весом, другой – с текущим).

Литература

1. Гмурман В.Е. Теория вероятностей и математическая статистика. – М.: Высшая школа, 1999. – 479 с.
2. Елисеева И.И., Юзбашев М.М. Общая теория статистики. – М.: Финансы и статистика, 1999. – 480 с.
3. Єріна А.М., Пальян З.О. Тоерія статистики. Практикум. – К.:Товариство “Знання”, КОО,1997. – 325 с.
4. Харченко Л.П. Долженкова В.Г., Ионин В.Г. Статистика: Курс лекций. – М.: ИНФРА-М, 1998. – 310 с.
5. Афиши А., Эйзен С. Статистический анализ. – М.: Мир, 1982. – 478 с.