

Прикладной многомерный статистический анализ

Теоретический минимум

Лектор: Хохлов Юрий Степанович

2016 г.

Вопрос №1 Основные задачи многомерного статистического анализа:

1. **Корреляционный анализ** изучает наличие и силу связи между случайными величинами. Используются коэффициенты корреляции.
2. **Регрессионный анализ.** Выделяются объясняемая переменная Y (отклик) и несколько объясняющих факторов $X_1, \dots, X_m$. Если обнаружено влияние факторов $X_1, \dots, X_m$ на Y , то пытаются найти вид их связи, в следующем формате

$$Y = g(X_1, \dots, X_m) + \varepsilon$$

где, $g(X_1, \dots, X_m)$ - влияние факторов, а ε - то, что не удалось объяснить.

3. **Методы снижения размерности.** Обычно размерность пространства факторов d - велика. Пытаются найти небольшое количество (возможно новых) факторов, которые достаточно хорошо представляют изменения в рамках исходной совокупности. Для этих целей применяют факторный анализ, главные компоненты и т.д.
4. **Дисперсионный анализ.** Поиск зависимостей в экспериментальных данных путём исследования значимости различий в средних значениях. Суть дисперсионного анализа сводится к изучению влияния одной или нескольких независимых переменных, обычно именуемых факторами, на зависимую переменную.
5. **Дискриминантный анализ.** Предположим, что наши данные неоднородны. Например они выбраны из 2-ух совокупностей с разным средним. В таком случае, основной задачей является нахождение процедуры позволяющей разделить все наблюдения по признаку принадлежности к одной из совокупностей.
6. **Кластерный анализ.** Схожий с дискриминантным анализ, но отсутствуют знания о классах. Визуально видно, что данные как-то группируются в несколько классов. Основной задачей является нахождение некоторого правила, объединяющего точки в один класс.

Вопрос №2 Гильбертово пространство случайных величин.

Линейное пространство случайных величин 1) на котором задано скалярное произведение, 2) доказана сходимости и относительная сходимости в среднем квадратическом, 3) которое полно относительно этой сходимости называется Гильбертовым пространством случайных величин.

Пусть L_2 есть пространство случайных величин ξ , таких, что

$$E(|\xi|^2) < \infty$$

Определим на L_2 следующий функционал: $\forall \xi_1, \xi_2 \in L_2$, по определению

$$(\xi_1, \xi_2) := E(\xi_1 \cdot \xi_2) \quad (1)$$

Обладающий следующими свойствами:

1. $(\xi, \xi) \geq 0$ и $(\xi, \xi) = 0 \Leftrightarrow \xi = 0$
2. $(\xi_1, \xi_2) = (\xi_2, \xi_1)$
3. $(C_1\xi_1 + C_2\xi_2, \xi_3) = C_1(\xi_1, \xi_3) + C_2(\xi_2, \xi_3)$

В таком случае этот функционал является скалярным произведением.

Нормой случайной величины ξ из L_2 называется число

$$\|\xi\| = \sqrt{(\xi, \xi)} = \sqrt{E(|\xi|^2)} \quad (2)$$

Последовательность случайных величин ξ_n из L_2 сходится в среднем квадратическом к случайной величине ξ_0 , если норма $\xi_n - \xi_0$ стремится к нулю при $n \rightarrow \infty$:

$$\|\xi_n - \xi_0\|^2 = E(|\xi_n - \xi_0|^2) \rightarrow 0$$

Если

$$E(|\xi_n - \xi_m|^2) \rightarrow 0, \text{ когда } m, n \rightarrow \infty$$

$$\exists \xi_0 \in L_2 : E(|\xi_n - \xi_0|^2) \rightarrow 0$$

то пространство L_2 является Гильбертовым пространством.

Вопрос №3 Что такое наилучшая линейная оценка(приближение)?

Пусть $H \subset L_2$ замкнутое линейное подпространство, а $\eta \in L_2$ случайная величина, для которой необходимо найти линейное приближение в H . Тогда случайная $\hat{\eta}$ есть **наилучшее линейное приближение** η в пространстве H , если

1. $\hat{\eta} \in H$
2. $\forall \xi \in H :$

$$\|\eta - \hat{\eta}\|^2 \leq \|\eta - \xi\|^2 \Leftrightarrow E(|\eta - \hat{\eta}|^2) \leq E(|\eta - \xi|^2)$$

Вопрос №4 Лемма о перпендикуляре.

Если $\hat{\eta}$ есть наилучшее линейное приближение η в пространстве H тогда:

$$1. \hat{\eta} \in H$$

$$2. \forall \xi \in H :$$

$$(\eta - \hat{\eta}, \xi) = E((\eta - \hat{\eta}) \cdot \xi) = 0 \quad (3)$$

Впрос №5 Простой коэффициент корреляции.

Простым или парным коэффициентом корреляции невырожденных случайных величин ξ_1 и ξ_2 называется число:

$$\rho(\xi_1, \xi_2) := \frac{\text{cov}(\xi_1, \xi_2)}{\sqrt{D(\xi_1) \cdot D(\xi_2)}}$$

Измеряет зависимость двух величин.

$|\rho(\xi_1, \xi_2)|^2$ измеряет долю изменчивости ξ_2 , которую можно объяснить линейным влиянием ξ_1 .

$1 - |\rho(\xi_1, \xi_2)|^2$ измеряет ту часть изменчивости ξ_2 , которую не удалось объяснить линейным влиянием ξ_1 и необходимо привлечь дополнительные факторы.

Вопрос №6 Множественный коэффициент корреляции.

Множественный коэффициент корреляции пытается объяснить поведение y с помощью нескольких факторов $x_1, x_2, \dots, x_m; m \geq 2$. Пусть $\hat{y} = \alpha + \beta_1 x_1 + \dots + \beta_m x_m$ - наилучшее линейное приближение y . Тогда, **множественным коэффициентом корреляции** случайной величины y и набора $x_1, \dots, x_m$ называется число

$$\rho_{y.x_1, \dots, x_m} := \rho(y, \hat{y})$$

$\rho_{y.x_1, \dots, x_m}^2$ показывает, какую долю изменчивости y можно объяснить линейным влиянием выбранных факторов.

Вопрос №7 Частный коэффициент корреляции.

Пусть изучаем зависимость y от факторов $x_1, \dots, x_m$. Выделим некоторый фактор x_k . Пусть C - набор всех остальных факторов, а y^C - наилучшее линейное приближение y через все x_i , кроме x_k - C . x_k^C - наилучшее приближение самого x_k через C . Тогда ошибки будут равны

$$z_y = y - y^C, z_{x_k} = x_k - x_k^C$$

Частным коэффициентом корреляции случайной величины y и x_k , когда устранено влияние всех остальных факторов называется:

$$\rho_{yx_k.C} = \rho(z_y, z_{x_k})$$

$\rho_{yx_k.C}^2$ - показывает какую долю необъяснённой дисперсии удалось объяснить введением нового фактора. Частный коэффициент корреляции измеряет чистое влияние фактора x_k на y .

Вопрос №8 Модель и основные ограничения множественной линейной регрессии.

Модель: проводится N одновременных измерений величины Y и факторов $X_1, \dots, X_d$. При этом предполагается, что

$$Y_j = g(X_{j1}, \dots, X_{jd}) + \varepsilon_j$$

Ограничения:

1. Модель линейна по параметрам, т.е.:

$$Y_j = \alpha + \beta_1 \cdot X_{j1} + \dots + \beta_d \cdot X_{jd} + \varepsilon_j$$

2. Факторы X_{jk} измерены точно, т.е. это не случайные величины.
3. $E(\varepsilon_j) = 0$ для любого j . Т.е. иксы в среднем правильно описывают поведение Y и нет систематических ошибок.
4. Дисперсия $D(\varepsilon_j) = \sigma^2 \forall j$ одинакова для всех j . Условие гомоскедастичности.
5. $cov(\varepsilon_j, \varepsilon_k) = 0$, когда $j \neq k$. Т.е. ошибки не коррелируют.
6. ε_j имеет нормальное распределение.

Вопрос №9 Описание метода наименьших квадратов для оценки параметров.

Пусть имеются следующие параметры модели:

$$\Theta_0, \Theta_1, \dots, \Theta_m \text{ и } \sigma^2 = D(\varepsilon_j)$$

Тогда для оценки параметров Θ_j необходимо решить следующую экстремальную задачу:

$$Q(\Theta) = \|Y - X \cdot \Theta\|^2 = \sum_{j=1}^N [Y_j - \Theta_0 - \Theta_1 X_{j1} - \dots - \Theta_m X_{jm}]^2 \rightarrow \min_{\Theta}$$

Необходимое условие экстремума:

$$\frac{\partial Q}{\partial \Theta_k} = 0, k = \overline{0, m}$$

После несложных преобразований получаем систему нормальных уравнений:

$$X^T \cdot X \cdot \Theta = X^T \cdot Y$$

Отсюда оценка параметра Θ по методу наименьших квадратов будет:

$$\hat{\Theta} = (X^T \cdot X)^{-1} \cdot X^T \cdot Y$$

Она является линейной, несмещенной и по теореме Гаусса - Маркова является оптимальной в среднем квадратическом в классе всех линейных и несмещенных оценок.

Вопрос №10 Явный вид оценок параметров по МНК.

Оценка параметра Θ :

$$\hat{\Theta} = (X^T \cdot X)^{-1} \cdot X^T \cdot Y$$

Оценка для среднего квадратического вектора остатков $\sigma^2 = D(\varepsilon_j) = E(\varepsilon_j^2)$ будет:

$$S^2 := \frac{1}{N - (m + 1)} \sum_{j=1}^N e_j^2$$

где $e = Y - \hat{Y}$.

Вопрос №11 Общая схема проверки гипотезы о параметре.

Статистической гипотезой называется утверждение о распределении генеральной совокупности, соответствующее некоторым представлениям об изучаемом явлении. В частном случае это может быть утверждение о значениях параметров нормально распределенной генеральной совокупности. Статистические гипотезы обычно рассматривают, генеральные совокупности, одна из которых может представлять собой теоретическую модель, а о второй судят по выборке из нее. В других случаях обе генеральные совокупности представлены выборками. Изначально формулируются 2 гипотезы H_0 и H_1 . Нулевая гипотеза гласит:

Между двумя генеральными совокупностями нет ожидаемого различия

Соответственно, альтернативная гипотеза H_1 заявляет об обратном.

Схема проверки:

1. Определяется уровень значимости $\alpha = (0.1, 0.05, 0.001)$.
2. По выборочным данным вычисляется значение некоторой новой случайной величины $K_{\text{набл}}$, которая имеет известное стандартное распределение. Например, T - распределение или F - распределение.
3. По таблицам соответствующего распределения (нормального, T - распределения и т.д.), находится значение критической константы при соответствующем уровне значимости - $k(\alpha)$.
4. Если реально полученное наблюдаемое значение $K_{\text{набл}}$ статистики K больше, по модулю, чем $k(\alpha)$, то гипотеза H_0 отвергается.
5. Если выяснилось обратное, то говорят, что H_0 не противоречит экспериментальным данным.

Вопрос №12 Для чего используется Т-критерий.

Т-критерий или критерий Стьюдента используется для проверки гипотез, где выборки имеют распределение близкое к нормальному. В случае одной выборки применяется для проверки какого-то утверждения, например:

$$E(X) = m$$

В случае двух выборок проверяются различия между ними.

В нашем курсе T - критерий использовался для проверки гипотез:

1. О том, что случайные величины X и Y независимы, тогда и только тогда, когда $\rho(X, Y) = 0$: $T := \frac{R}{\sqrt{1 - R^2}} \cdot \sqrt{N - 2}$
2. О том, что повторная выборка из одномерного нормального распределения $N(a, \frac{\sigma^2}{N})$ имеет такое же мат.ожидание, как и первая выборка:

$$T := \frac{\bar{X} - a}{S_1} \sqrt{N}$$
3. О значимости влияния отдельного фактора в присутствии всех остальных: $T := \frac{\hat{\theta}_k}{S_k}$

Вопрос №13 Основное различие Т-критерия и F-критерия в задаче проверки значимости влияния фактора

Пусть есть такая линейная модель регрессии:

$$Y = X \cdot \Theta + \varepsilon$$

$$Y_j = \Theta_0 + \Theta_1 \cdot X_{j1} + \dots + \Theta_n \cdot X_{jn} + \varepsilon_j$$

Проверяется, что

- $H_0 : \Theta_k = 0$ (фактор не значим), против
- $H_1 : \Theta_k \neq 0$ (фактор значим).

В данной задаче:

1. T - критерий проверяет значимость влияния отдельного фактора в присутствии всех остальных факторов.
2. F - критерий оценивает чистое влияние отдельного фактора, когда все остальные факторы устранены.

Очевидно, что если фактор всего один, то оба критерия эквивалентны.

Вопрос №14 Адекватность модели. Постановка задачи.

Модель регрессии $Y = X \cdot \Theta + \varepsilon$ считается адекватной, если предложенный набор факторов $X_1, \dots, X_n$ оказывает совместно значимое влияния на Y .

Формально, проверяется гипотеза:

- $H_0 : \Theta_1 = \Theta_2 = \dots \Theta_m = 0$, против
- $H_1 : \Theta_k \neq 0$.

Если H_0 отвергается, то модель считается адекватной. В противном случае, выбранный набор фактор не оказывает значимого влияния Y и модель не адекватна. Необходимо выбрать другие факторы.

Вопрос №15 Коэффициент детерминации и что он измеряет.

Можно показать, что справедливо следующее тождество:

$$\sum_{j=1}^N [Y_j - \bar{Y}]^2 = \sum_{j=1}^N [Y_j - \hat{Y}_j]^2 + \sum_{j=1}^N [\hat{Y}_j - \bar{Y}]^2$$

Для сокращения, эту формулу записывают по другому:

$$TSS = ESS + RSS$$

где

1. TSS - полная сумма квадратов.

2. ESS - сумма квадратов остатков.
3. RSS - объясненная сумма квадратов.

Коэффициентом детерминизации называется число:

$$R^2 := \frac{RSS}{TSS}$$

R^2 - это оценка квадрата множественного коэффициента корреляции. Иными словами это доля дисперсии зависимой переменной, объясняемая рассматриваемой моделью зависимости, то есть объясняющими переменными. Чем ближе он к 1, тем лучше выбранная модель.

Вопрос №16 Основная задача в однофакторном дисперсионном анализе. Пусть имеется следующий набор измерений:

$$Y_{kj} = \mu_k + \varepsilon_{kj}; \quad k = \overline{1, m}, j = \overline{1, N} \quad (1)$$

где, k - уровень фактора, j - номер измерения. Предполагается:

1. μ_k - неслучайные вещественные числа;
2. ε_{kj} - имеют многомерное нормальное распределение $N(0, \sigma^2) \forall k, j$;
3. ε_{kj} - независимы для любых k, j . Запишем модель в новом виде:

$$\mu = \frac{1}{m} \sum_{k=1}^m \mu_k; \quad \alpha_k = \mu_k - \mu \Rightarrow \sum \alpha_k = 0$$

Отсюда, $Y_{jk} = \mu + \alpha_k + \varepsilon_{jk}$, что эквивалентно (1).

Основная задача: Есть ли различия в поведении Y на различных уровнях. Более формально можно записать:

Проверяется гипотеза:

1. $H_0 : \alpha_k = 0 : \quad \forall k$, против
2. $H_1 : \exists k : \alpha_k \neq 0$

Вопрос №17 Основная задача в двухфакторном дисперсионном анализе. Пусть имеется следующая модель измерений (для каждого сочетания факторов по одному измерению):

$$Y_{kj} = \mu_{kj} + \varepsilon_{kj}; \quad k = \overline{1, m}; j = \overline{1, N}; n = m \cdot N \quad (1)$$

Предполагается, что на исследование влияют 2 фактора:

1. k - уровень первого фактора;
2. j - уровень второго фактора;

Предполагается, что :

1. μ_{kj} - константа;
2. ε_{kj} - случайные, независимые;
3. ε_{kj} - имеет многомерное нормальное распределение $N(0, \sigma^2)$

Введем следующие обозначения:

$$\mu_{\bullet\bullet} = \frac{1}{n} \sum_{kj} \mu_{kj}; \quad \mu_{\bullet j} = \frac{1}{m} \sum_k \mu_{kj}; \quad \mu_{k\bullet} = \frac{1}{N} \sum_j \mu_{kj}$$

Тогда, $\tau_j := \mu_{\bullet j} - \mu_{\bullet\bullet}$ - эффект столбца, а $\zeta_k := \mu_{k\bullet} - \mu_{\bullet\bullet}$ - эффект строки.

Основная задача: Есть ли влияние факторов - эффект столбца или эффект строки?

Более формально, для эффекта строки, проверяется разница в средних по строкам. Ещё более формально, проверяется:

- $H_0 : \zeta_1, \zeta_2, \dots, \zeta_m = 0$, против
- $H_1 : \exists k : \zeta_k \neq 0$.

Вопрос №18 Основная задача дискриминантного анализа. Пусть каждый изучаемый объект характеризуется парой чисел $X = (X_1, X_2)$, предполагается, что (X_1, X_2) имеет двумерное нормальное распределение со средним $\mu = \begin{pmatrix} \mu_1 \\ \mu_2 \end{pmatrix}$ и некоторой матрицей ковариаций Σ .

Пусть имеется две совокупности, которые различаются средними $\mu^{(1)} = (\mu_1^{(1)}, \mu_2^{(1)})$ и $\mu^{(2)} = (\mu_1^{(2)}, \mu_2^{(2)})$, но имеют одну и ту же матрицу ковариаций Σ .

Основная задача: Отнести вновь поступивший объект (X_1, X_2) к одной из этих совокупностей.

Вопрос №19 Кластерный анализ: постановка задачи.

Пусть из некоторого множества π (*генеральной совокупности*) отобрано n объектов $I = (I_1, \dots, I_n)$. У каждого из этих объектов измеряется несколько характеристик $C = (C_1, \dots, C_p)^T$. Предполагается, что эти характеристики являются *количественными*. Пусть, x_{ij} есть результат измерения

i -й характеристики у объекта I_j . Тогда $X_j = (x_{1j}, \dots, x_{pj})^T$ есть измерения всех его характеристик у объекта I_j . В итоге имеем матрицу измерений:

$$X = (X_1, \dots, X_n).$$

Далее каждый набор X_j рассматривается как вектор в пространстве $\mathbb{R}^p$. Пусть $m < n$, тогда **основная задача**: на основе измерений X разбить множество объектов I на m классов (*кластеров*) $\pi_1, \dots, \pi_m$, так чтобы:

1. каждый объект I_j принадлежал одному и только одному классу;
2. объекты внутри одного класса были бы "*сходными*";
3. объекты из разных классов были бы "*несходными*".

Интуитивно ясно, что объекты I_j и I_k нужно отнести в один класс, если расстояние между X_j и X_k будет *достаточно малым*, а между точками из разных классов *достаточно большим*.

Вопрос №20 Кластерный анализ: последовательное построение факторов (кластеров?).

1. Сначала все объекты рассматривают как отдельные кластеры.
2. Выбирают 2 порога s и r .
3. Если все кластеры находятся на расстоянии более, чем s , то процедура заканчивается.
4. Если есть кластеры, которые ближе друг к другу, чем s , то находим два наиболее близких и объединяем их.
5. Находим расстояния внутри кластеров и расстояния между кластерами.
6. Процедура продолжается до тех пор, пока расстояния внутри всех кластеров не более чем r , а между кластерами не более чем s .