

# ОСНОВЫ ХИМИЧЕСКОЙ МЕТРОЛОГИИ

## Лекция 4 Дисперсионный анализ

лектор: Образовский Е. Г.

3 марта 2015 г.

Общая погрешность анализа складывается из погрешностей различных этапов. Если возникает необходимость уменьшения общей погрешности анализа, следует проанализировать вклады отдельных этапов анализа. Этой цели и служит дисперсионный анализ.

Наиболее существенные вклады в общую погрешность в разных ситуациях могут давать различные этапы анализа.

Однако, как показывает практика, во многих случаях наиболее заметный вклад дает процедура пробоотбора.

Располагая достаточной информацией, в отдельных случаях можно оценить погрешность пробоотбора теоретически.

Например, если исходный материал состоит из отдельных частиц (гранул), каждая из которых либо содержит (с вероятностью  $p$ ), либо не содержит определяемый компонент, то в отобранной из большого объема пробе из  $n$  частиц в среднем  $\mu = np$  частиц содержат определяемый компонент. Вероятность  $f(m)$  найти  $m$  частиц с определяемым компонентом дается распределением Пуассона:

$$f(m) = \frac{\mu^m}{m!} \cdot e^{-\mu}.$$

Тогда погрешность пробоотбора  $s_{\Pi}$  определяется среднеквадратичным отклонением

$$s_{\Pi} = \sqrt{\mu} = \sqrt{np}, \quad s_{\Pi \text{ отн}} = \frac{\sqrt{\mu}}{\mu} = \frac{1}{\sqrt{np}}.$$

Задавая необходимую погрешность пробоотбора и зная приблизительно долю определяемого компонента в анализируемом материале, мы можем рассчитать необходимое количество частиц (гранул) в пробе для анализа.

$$n = \frac{1}{ps_{\Pi}^2}.$$

# Дисперсионный анализ

СКОЙ  
МЕТРОЛО-  
ГИИ

Лекция 4  
Дисперсион-  
ный  
анализ

лектор: Об-  
разовский  
Е. Г.

*Пример* Рассмотрим два случая.

а) Для вероятности содержания определяемого компонента  $p = 0,1$  и допустимого значения относительного стандартного отклонения пробоотбора  $S_p = 0,01$  по приведенной формуле получаем, что минимальное необходимое значение числа частиц в пробе для анализа составляет  $n = 10^5$ .

б) Для  $1 \text{ дм}^3$  водного раствора, содержащего  $10^{-6} \text{ М NaCl}$ , получаем  $p = 10^{-6}/55,5 = 2 \cdot 10^{-8}$ . Тогда для  $S_p = 0,0001$  минимальное число частиц  $n = 5 \cdot 10^{15}$ , т. е. необходимый минимальный объем составляет всего  $V \approx 2 \cdot 10^{-10} \text{ дм}^3$ .

Зная стандартные отклонения пробоотбора и анализа, можно оптимизировать общую погрешность. Например, пусть имеется  $n$  образцов и у нас есть возможность проанализировать  $k (< n)$  проб. Рассмотрим две схемы анализа.

*Схема 1.* Анализируем  $k$  из  $n$  образцов и за результат анализа берем среднее значение. Тогда

$$\bar{s}_a^{(1)} = \frac{S_a}{\sqrt{k}}, \quad \bar{s}_n^{(1)} = \frac{S_n}{\sqrt{k}}, \quad \bar{s}^{(1)} = \frac{\sqrt{S_a^2 + S_n^2}}{\sqrt{k}}.$$

*Схема 2.* Смешиваем  $n$  образцов и выбираем из смеси  $k$  проб для анализа. Перемешивание уменьшает дисперсию пробоотбора

$$\bar{S}_n = \frac{S_n}{\sqrt{n}},$$

но не меняет дисперсию анализа, так что при анализе  $k$  образцов из смеси среднеквадратичное отклонение для среднего значения равно

$$\bar{S}^{(2)} = \frac{\sqrt{S_a^2 + S_n^2/n}}{\sqrt{k}} < \bar{S}^{(1)}.$$

*Пример* От большого количества материала отобрано 10 образцов, погрешность пробоотбора  $S_n = 0,10$ , погрешность единичного определения интересующего компонента  $S_a = 0,05$ . Рассмотрим следующие планы анализа.

*План 1.* Анализируем 10 проб и за результат анализа принимаем среднее значение. Тогда

$$\bar{S}^{(1)} = \frac{\sqrt{(0,05)^2 + (0,10)^2}}{\sqrt{10}} = 0,035.$$

*План 2.* Перемешиваем 10 образцов и анализируем 1 пробу. Тогда

$$\bar{S}^{(2)} = \sqrt{(0,05)^2 + (0,10)^2/10} = 0,059.$$



*План 3.* Перемешиваем 10 образцов и анализируем 10 проб.  
Тогда

$$\bar{s}(3) = \frac{\sqrt{(0,05)^2 + (0,10)^2/10}}{\sqrt{10}} = 0,019.$$

*План 4.* Перемешиваем 10 образцов и анализируем 3 пробы.  
Тогда

$$\bar{s}(4) = \frac{\sqrt{(0,05)^2 + (0,10)^2/10}}{\sqrt{3}} = 0,034.$$

Из приведенных данных видно, что план анализа № 4, будучи значительно экономичнее плана № 1, дает даже немного лучшие результаты.

# Дисперсионный анализ

СКОЙ  
МЕТРОЛО-  
ГИИ  
Лекция 4  
Дисперсион-  
ный  
анализ

лектор: Об-  
разовский  
Е. Г.

*Сравнение двух схем анализа.*

# Простой дисперсионный анализ

СКОЙ  
МЕТРОЛО-  
ГИИ

Лекция 4  
Дисперсион-  
ный  
анализ

лектор: Об-  
разовский  
Е. Г.


В подавляющем большинстве случаев разложение ошибок на составляющие проводится экспериментально.

Рассмотрим простейший случай разложения ошибки анализа на две составляющие, например на ошибку пробоотбора и ошибку собственно анализа. Для этого используют следующую схему эксперимента. От большой партии исходного материала отбирают  $m$  проб, каждая анализируется  $n_j$  раз, рис.1.

# Простой дисперсионный анализ

СКОЙ  
МЕТРОЛО-  
ГИИ  
Лекция 4  
Дисперсион-  
ный  
анализ

лектор: Об-  
разовский  
Е. Г.



# Простой дисперсионный анализ

СКОЙ  
МЕТРОЛО-  
ГИИ

Лекция 4  
Дисперсион-  
ный  
анализ

лектор: Об-  
разовский  
Е. Г.

Отобранные пробы гомогенизируют, так что среднеквадратичное отклонение при анализе отдельных проб примерно одинаково (что проверяется с помощью статистических критериев, например, критерия Кохрена). Однако из-за неоднородности исходной пробы средние результаты анализов различных проб имеют отклонения, что становится дополнительной причиной ошибок, увеличивая случайную ошибку метода. Дисперсия средних между пробами

$$S_1^2 = \frac{\sum_{i=1}^m (\bar{x}_j - \bar{x})^2}{m - 1}$$

складывается из дисперсии внутри проб

$$S_2^2 = \frac{1}{m} \sum_{i=1}^m \frac{1}{n_j - 1} \sum_{j=1}^{n_j} (x_{ij} - \bar{x}_j)^2$$

и из дисперсии пробоотбора  $S_n^2$ .

# Простой дисперсионный анализ

СКОЙ  
МЕТРОЛО-  
ГИИ  
Лекция 4  
Дисперсион-  
ный  
анализ

лектор: Об-  
разовский  
Е. Г.

В случае значимости различия между  $S_1^2 \cdot n_j$  и  $S_2^2$ , проверяемой по  $F$ -критерию Фишера, т. е. при условии

$$F = \frac{S_1^2 \cdot n_j}{S_2^2} > F_{\text{табл}}(P = 0,95; \nu_1 = m - 1; \nu_2 = (n_j - 1)m),$$

погрешность пробоотбора определяется по формуле

$$S_{\text{п}} = \sqrt{S_1^2 - \frac{S_2^2}{n_j}}.$$

Эффективность дисперсионного анализа зависит также от соотношения погрешности пробоотбора  $S_s$  и анализа  $S_a$ ,  
Ниже приведены данные относительной доли экспериментов, в которых наблюдаются незначимые отличия дисперсий по критерию Фишера для двух значений  $S_s/S_a = 2.0$  и  $S_s/S_a = 3.0$  для случая  $m = 6, n_j = 2$ .

# Дисперсионный анализ

СКОЙ  
МЕТРОЛО-  
ГИИ

Лекция 4  
Дисперсион-  
ный  
анализ

лектор: Об-  
разовский  
Е. Г.

Относительная доля экспериментов, в которых наблюдаются незначимые отличия дисперсий по критерию Фишера для двух значений  $S_s/S_a = 2.0$  и  $S_s/S_a = 3.0$  для случая  $m = 6, n_j = 2$ .



# Простой дисперсионный анализ

СКОЙ  
МЕТРОЛО-  
ГИИ

Лекция 4  
Дисперсион-  
ный  
анализ

лектор: Об-  
разовский  
Е. Г.

Для эффективного применения данной схемы разделения ошибок на составляющие необходимо выбрать оптимальное соотношение между числом отбираемых точечных проб  $m$  и числом параллельных анализов каждой отобранной пробы  $n_j$ .

В этом нам помогают результаты численного моделирования. Рассмотрим в качестве примера три схемы, при которых полное число анализируемых проб  $m \cdot n_j$  постоянно:

# Дисперсионный анализ

СКОЙ  
МЕТРОЛО-  
ГИИ  
Лекция 4  
Дисперсион-  
ный  
анализ

лектор: Об-  
разовский  
Е. Г.

1.  $m = 5, n_j = 8$ . Небольшое число параллельных проб приводит к большому разбросу результатов определения  $S_S$

# Дисперсионный анализ

СКОЙ  
МЕТРОЛО-  
ГИИ

Лекция 4  
Дисперсион-  
ный  
анализ

лектор: Об-  
разовский  
Е. Г.

1.  $m = 5, n_j = 8$ . Небольшое число параллельных проб приводит к большому разбросу результатов определения  $S_S$

2.  $m = 10, n_j = 4$ . Увеличение числа параллельных проб приводит к уменьшению разброса результатов определения  $S_S$  даже при увеличении разброса результатов определения  $S_a$

2.  $m = 10, n_j = 4$ . Увеличение числа параллельных проб приводит к уменьшению разброса результатов определения  $S_S$  даже при увеличении разброса результатов определения  $S_a$

# Дисперсионный анализ

СКОЙ  
МЕТРОЛО-  
ГИИ

Лекция 4  
Дисперсион-  
ный  
анализ

лектор: Об-  
разовский  
Е. Г.

3.  $m = 20, n_j = 2$ . Дальнейшее увеличение числа параллельных проб приводит к большему уменьшению разброса результатов определения  $S_S$  несмотря на заметное увеличение разброса результатов определения  $S_a$

# Дисперсионный анализ

СКОЙ  
МЕТРОЛО-  
ГИИ

Лекция 4  
Дисперсион-  
ный  
анализ

лектор: Об-  
разовский  
Е. Г.

3.  $m = 20, n_j = 2$ . Дальнейшее увеличение числа параллельных проб приводит к большему уменьшению разброса результатов определения  $S_S$  несмотря на заметное увеличение разброса результатов определения  $S_a$

Данные численного моделирования позволяют сделать вывод, что наиболее эффективной является схема 3.  $m = 20, n_j = 2$ , поскольку именно она дает наиболее узкую функцию распределения для стандартного отклонения погрешности пробоотбора.



# Простой дисперсионный анализ

*Пример* От большой партии исходного материала отобрали  $m = 6$  проб и каждую проанализировали  $n_j = 2$  раза. Результаты приведены в таблице в строках 2 и 3. По этим данным рассчитывают средние

$$\bar{x}_i = \frac{x_{i1} + x_{i2}}{2}, \quad s_i^2 = \frac{(x_{i1} - x_{i2})^2}{2},$$

которые также приведены в таблице в строках 3 и 4.

$i$	1	2	3	4	5	6
$j = 1$	14,72	15,51	14,60	15,10	14,70	14,74
$j = 2$	15,05	15,23	14,35	15,23	14,95	14,50
$x_i$	14,885	15,370	14,475	15,165	14,825	14,620
$s_i$	0,233	0,198	0,177	0,092	0,177	0,170

# Простой дисперсионный анализ

СКОЙ  
МЕТРОЛО-  
ГИИ

Лекция 4  
Дисперсион-  
ный  
анализ

лектор: Об-  
разовский  
Е. Г.

Проверяем однородность значений относительных стандартных отклонений  $S_i$  по критерию Кохрена. Для этого рассчитываем тестовую статистику

$$C = \frac{S_{\max}^2}{\sum_{i=1}^m S_i^2} = \frac{0,0543}{0,194} = 0,281$$

и сравниваем с табличным  $C_{5\%}(m = 6, n = 2) = 0,781$ . Поскольку рассчитанное значение тестовой статистики не превышает 5 %-го критического значения, совокупность стандартных отклонений можно считать однородной.

# Простой дисперсионный анализ

СКОЙ  
МЕТРОЛО-  
ГИИ

Лекция 4  
Дисперсион-  
ный  
анализ

лектор: Об-  
разовский  
Е. Г.

Тогда рассчитываем величины

$$\bar{x} = \sum_{i=1}^m \bar{x}_i / m = 14,890,$$

$$S_1^2 = \frac{\sum_{i=1}^m (\bar{x}_i - \bar{x})^2}{m - 1} = 0,111, \quad S_2^2 = \frac{\sum_{i=1}^m S_i^2}{m} = 0,0323$$

и проверяем значимость отличия  $S_1$  и  $S_2$  по критерию Фишера:

$$F = \frac{S_1^2 \cdot n_j}{S_2^2} = 6,87 > F_{\text{табл}}(P = 0,95; \nu_1 = 5; \nu_2 = 6) = 4,39.$$

Тогда погрешность пробоотбора равна

$$S_{\text{п}} = \sqrt{S_1^2 - \frac{S_2^2}{2}} = 0,31.$$

# Классификация или факторный анализ

СКОЙ  
МЕТРОЛО-  
ГИИ

Лекция 4  
Дисперсион-  
ный  
анализ

лектор: Об-  
разовский  
Е. Г.

Для решения многих практических задач недостаточно определить содержания одной или нескольких компонент, часто необходимо на основе полученных данных классифицировать объекты анализа.  
Например

# Классификация или факторный анализ

СКОЙ  
МЕТРОЛО-  
ГИИ

Лекция 4  
Дисперсион-  
ный  
анализ

лектор: Об-  
разовский  
Е. Г.

Для решения многих практических задач недостаточно определить содержания одной или нескольких компонент, часто необходимо на основе полученных данных классифицировать объекты анализа.

Например

- классифицировать улики в судебном анализе

# Классификация или факторный анализ

СКОЙ  
МЕТРОЛО-  
ГИИ

Лекция 4  
Дисперсион-  
ный  
анализ

лектор: Об-  
разовский  
Е. Г.

Для решения многих практических задач недостаточно определить содержания одной или нескольких компонент, часто необходимо на основе полученных данных классифицировать объекты анализа.

Например

- классифицировать улики в судебном анализе
- идентифицировать источники загрязнения окружающей среды по результатам анализа проб воздуха, почвы, воды

# Классификация или факторный анализ

СКОЙ  
МЕТРОЛО-  
ГИИ

Лекция 4  
Дисперсион-  
ный  
анализ

лектор: Об-  
разовский  
Е. Г.

Для решения многих практических задач недостаточно определить содержания одной или нескольких компонент, часто необходимо на основе полученных данных классифицировать объекты анализа.

Например

- классифицировать улики в судебном анализе
- идентифицировать источники загрязнения окружающей среды по результатам анализа проб воздуха, почвы, воды
- классифицировать археологические находки на основе анализа микроэлементов

# Классификация или факторный анализ

СКОЙ  
МЕТРОЛО-  
ГИИ

Лекция 4  
Дисперсион-  
ный  
анализ

лектор: Об-  
разовский  
Е. Г.

Имеется множество объектов, в каждом из которых определена совокупность некоторых свойств (например, концентрации нескольких элементов). Задача заключается в нахождении или предсказании свойств объекта, которое непосредственному измерению не подвергалось, но так что оно считалось косвенно связанным с измерением через неизвестные или неопределенные соотношения.



# Классификация или факторный анализ

СКОЙ  
МЕТРОЛО-  
ГИИ

Лекция 4  
Дисперсион-  
ный  
анализ

лектор: Об-  
разовский  
Е. Г.

Например, имеются археологические изделия и требуется установить из какого из многих возможных источников они получены. Для этой цели определяется элементный состав возможных источников и проводится классификация этих источников (разбиение на некоторое число классов). Затем по элементному составу неизвестного образца относят его к тому или иному классу (источнику).

В данном примере совокупностью объектов являются образцы из возможных источников, а свойствами – концентрации элементов в этих образцах.

Исходные данные для классификации удобно представить в виде матрицы

# Классификация или факторный анализ

СКОЙ  
МЕТРОЛО-  
ГИИ  
Лекция 4  
Дисперсион-  
ный  
анализ

лектор: Об-  
разовский  
Е. Г.

$$\hat{X} = \begin{pmatrix} X_{11} & X_{12} & \dots & X_{1k} & \dots & X_{1p} \\ X_{21} & X_{22} & \dots & X_{2k} & \dots & X_{2p} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ X_{i1} & X_{i2} & \dots & X_{ik} & \dots & X_{ip} \\ \dots & \dots & \dots & \dots & \dots & \dots \\ X_{n1} & X_{n2} & \dots & X_{nk} & \dots & X_{np} \end{pmatrix},$$

где  $i$  – номер объекта,  $k$  – элемент. Содержания различных элементов могут существенно различаться и для того чтобы они все могли быть использованы для классификации необходимо провести масштабирование данных.

# Классификация или факторный анализ

СКОЙ  
МЕТРОЛО-  
ГИИ

Лекция 4  
Дисперсион-  
ный  
анализ

лектор: Об-  
разовский  
Е. Г.

Наиболее естественным является так называемое автомасштабирование, когда данные преобразуются согласно

$$x'_{ik} = \frac{x_{ik} - \bar{x}_k}{s_k},$$

где

$$\bar{x}_k = \frac{1}{n} \sum_{i=1}^n x_{ik}, \quad s_k = \sqrt{\frac{1}{n-1} \sum_{i=1}^n (x_{ik} - \bar{x}_k)^2}.$$

Существует множество методов проведения классификации. В качестве примера мы рассмотрим *проекционный метод* и *кластерный анализ*.

## Проекционный метод

Проекционный метод основан на выполнении вращения матрицы данных так, чтобы первая новая ось отвечала направлению наибольшей дисперсии данных, а каждая последующая ось — максимуму остаточной дисперсии. В качестве примера рассмотрим возможность отнесение объектов к трем классам по следующим результатам определения их элементного состава (концентрации элементов в исходных данных приведена в ppm).

# Проекционный метод

СКОЙ  
МЕТРОЛО-  
ГИИ

Лекция 4  
Дисперсион-  
ный  
анализ

лектор: Об-  
разовский  
Е. Г.

$$\hat{X} = \begin{pmatrix} Cu & Mn & Cl & Br & I \\ 9.2 & 0.30 & 1730 & 12.0 & 3.6 \\ 12.4 & 0.39 & 930 & 50.0 & 2.3 \\ 7.2 & 0.32 & 2750 & 65.3 & 3.4 \\ 10.2 & 0.36 & 1500 & 3.4 & 5.3 \\ 10.1 & 0.50 & 1040 & 39.2 & 1.9 \\ 6.5 & 0.20 & 2490 & 90.0 & 4.6 \\ 5.6 & 0.29 & 2940 & 88.0 & 5.6 \\ 11.8 & 0.42 & 867 & 43.1 & 1.5 \\ 8.5 & 0.25 & 1620 & 5.2 & 6.2 \end{pmatrix}.$$

После автомасштабирования матрица данных принимает следующий вид

$$\hat{X} = \begin{pmatrix} 0.06 & -0.40 & -0.04 & -0.97 & -0.13 \\ 1.44 & 0.58 & -1.05 & 0.18 & -0.89 \\ -0.80 & -0.18 & 1.25 & 0.64 & -0.25 \\ 0.49 & 0.25 & -0.33 & -1.23 & 0.87 \\ 0.45 & 1.78 & -0.91 & -0.15 & -1.13 \\ -1.10 & -1.49 & 0.92 & 1.39 & 0.46 \\ -1.48 & -0.51 & 1.49 & 1.33 & 1.04 \\ 1.18 & 0.91 & -1.13 & -0.03 & -1.36 \\ -0.24 & -0.95 & -0.18 & -1.17 & 1.40 \end{pmatrix}.$$

# Проекционный метод

СКОЙ  
МЕТРОЛО-  
ГИИ  
Лекция 4  
Дисперсион-  
ный  
анализ

лектор: Об-  
разовский  
Е. Г.

Матрица поворота  $\hat{R}$  составлена из собственных векторов матрицы ковариации исходных преобразованных данных

$$\hat{C} = \frac{1}{p-1} \hat{X}^T \cdot \hat{X},$$

и имеет вид

$$\hat{R} = \begin{pmatrix} -0.52 & 0.11 & 0.41 & 0.21 & 0.71 \\ -0.46 & -0.27 & -0.79 & 0.28 & 0.07 \\ 0.52 & -0.17 & -0.31 & -0.36 & 0.69 \\ 0.28 & -0.76 & 0.28 & 0.52 & 0.00 \\ 0.41 & 0.56 & -0.17 & 0.69 & 0.12 \end{pmatrix},$$

а собственные значения

$$\lambda = ( 26.8 \quad 9.5 \quad 2.3 \quad 1.1 \quad 0.4 ).$$

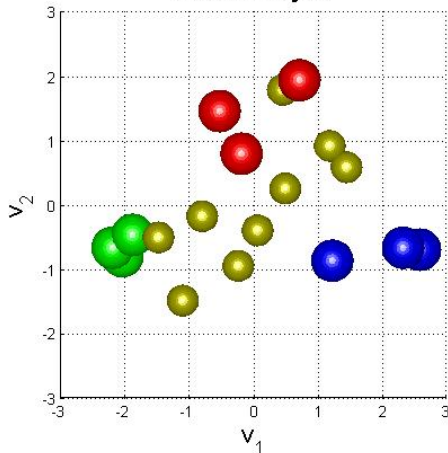
# Проекционный метод

СКОЙ  
МЕТРОЛО-  
ГИИ  
Лекция 4  
Дисперсион-  
ный  
анализ

лектор: Об-  
разовский  
Е. Г.

Преобразованные с помощью проекционного метода данные, в отличие от исходных, однозначно разбиваются на три класса в пространстве двух параметров.

Factor analysis





## Кластерный анализ

Кластерный анализ использует для классификации понятие расстояния между объектами, определяемого как

$$d_{ij} = \sqrt{\sum_{k=1}^p (x_{ik} - x_{jk})^2}.$$

Совокупность всех расстояний можно представить в виде матрицы

$$\hat{D} = \begin{pmatrix} 0 & 0 & \dots & \dots & 0 \\ d_{21} & 0 & \dots & \dots & 0 \\ d_{31} & d_{32} & 0 & \dots & 0 \\ \dots & \dots & \dots & \dots & 0 \\ d_{n1} & d_{n2} & \dots & d_{nn-1} & 0 \end{pmatrix}.$$

# Кластерный анализ

СКОЙ  
МЕТРОЛО-  
ГИИ  
Лекция 4  
Дисперсион-  
ный  
анализ

лектор: Об-  
разовский  
Е. Г.

Среди всех расстояний находится минимальное, например  $d_{ij}$ , и тогда объекты  $i$  и  $j$  объединяются в один кластер. Все расстояния пересчитываются, например, новое расстояние от полученного кластера  $ij$  до объекта  $k$  вычисляют как

$$d_{k(ij)} = \frac{d_{ki} + d_{kj}}{2}.$$

Процедуру повторяют снова до тех пор пока не останется необходимое число кластеров. Это удобно представить в виде дендрограммы, рис.2.

# Кластерный анализ

СКОЙ  
МЕТРОЛО-  
ГИИ

Лекция 4  
Дисперсион-  
ный  
анализ

лектор: Об-  
разовский  
Е. Г.




Рис.: Дендрограмма

