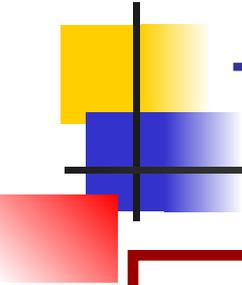


Методы многомерной калибровки: PCR/PLS

Андрей Богомолов

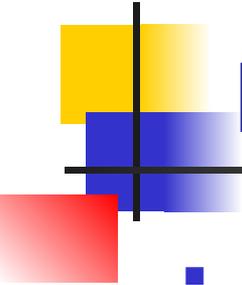
Российское хемометрическое общество



Тема лекции

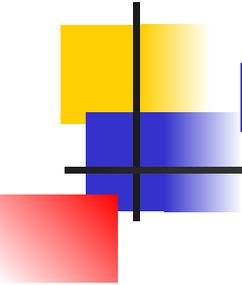
Многомерная калибровка Multivariate Calibration

Анализ многомерных данных (Хемометрика)
Multivariate Data Analysis (Chemometrics)

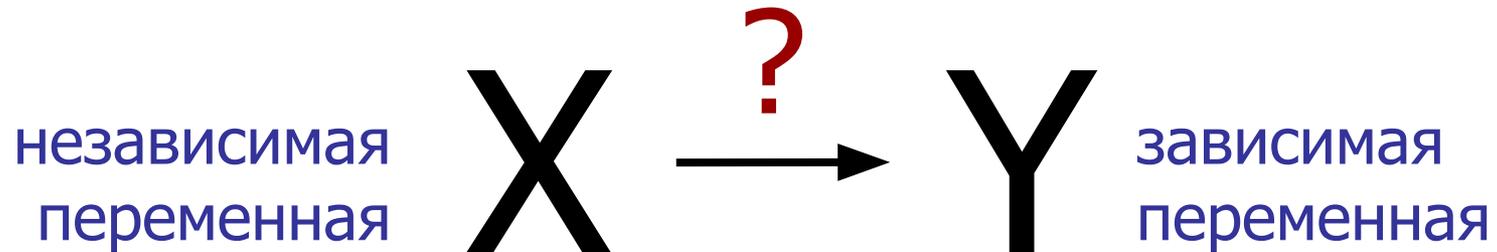


К вопросу о русской терминологии

- родной язык хемометрики - английский
- терминология за 30 лет устоялась: статьи, учебники, книги, конференции
- устоявшиеся аббревиатуры: **PCA, PCR, PLS, SIMCA, RMSEP, etc.** - не нуждаются в расшифровке
- русская терминология создается сейчас
- почему нужен перевод?
- в настоящей лекции - параллельная терминология



Регрессионный анализ



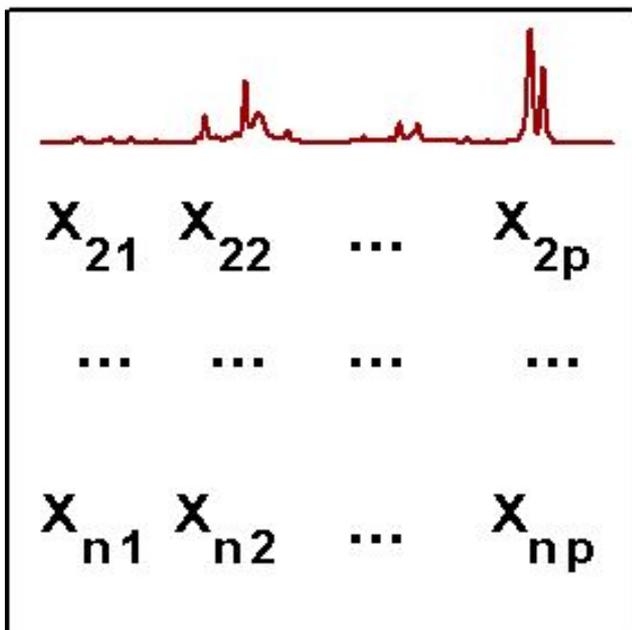
- линейная регрессия

$$\mathbf{Y} = \mathbf{XB} + \mathbf{E}$$

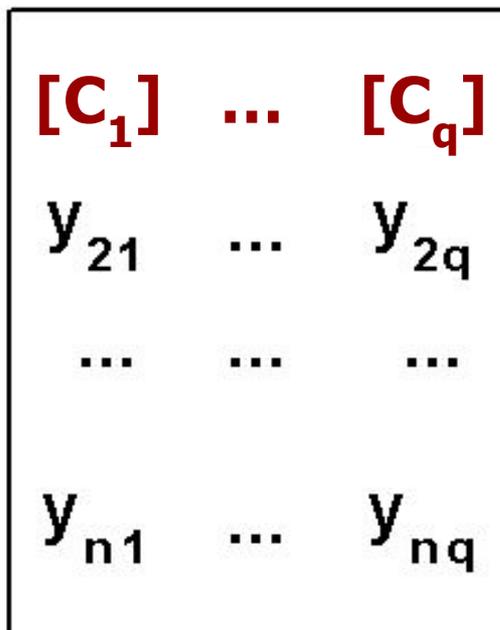
- МГК - моделирование (**X**)
- Регрессия - моделирование (**X,Y**)

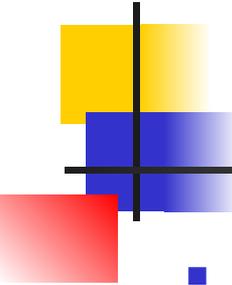
Спектроскопические данные

Спектры (X)



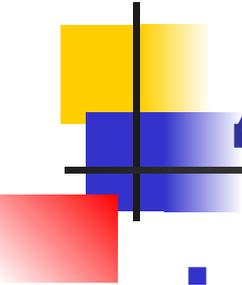
Концентрации (Y)





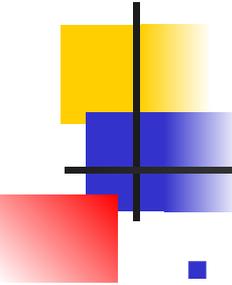
Регрессия & Калибровка

- “**Regression** is an approach for relating two sets of variables to each other”
Kim Esbensen
- “**Calibration** is a process of constructing a mathematical model to relate the output of an instrument to properties of samples”
Kenneth Beebe
- Калибровка ~ Регрессия



Для чего нужна калибровка?

- замена прямого измерения интересующего свойства, измерением другого, коррелирующего с первым
- такая потребность возникает если прямое измерение интересующего свойства нежелательно:
 - дорого
 - трудоемко
 - занимает много времени
 - этически нежелательно
 - эксперимент невозможен, и т. п.
- в подавляющем числе практических ситуаций такая замена оправдана!

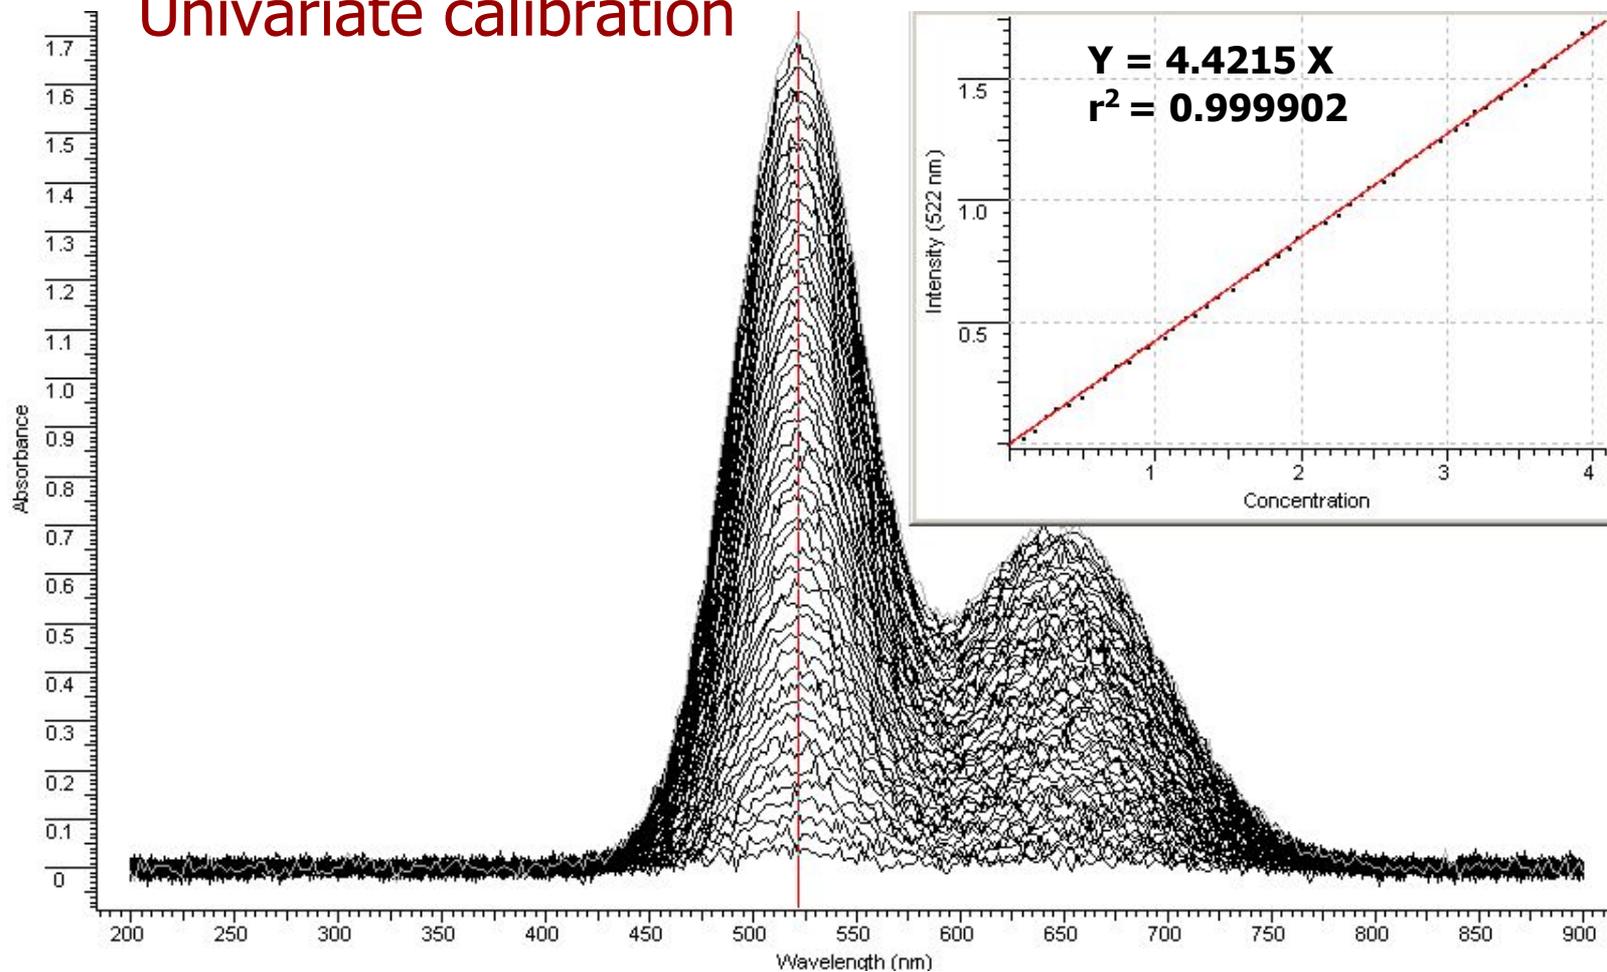


Примеры из различных областей

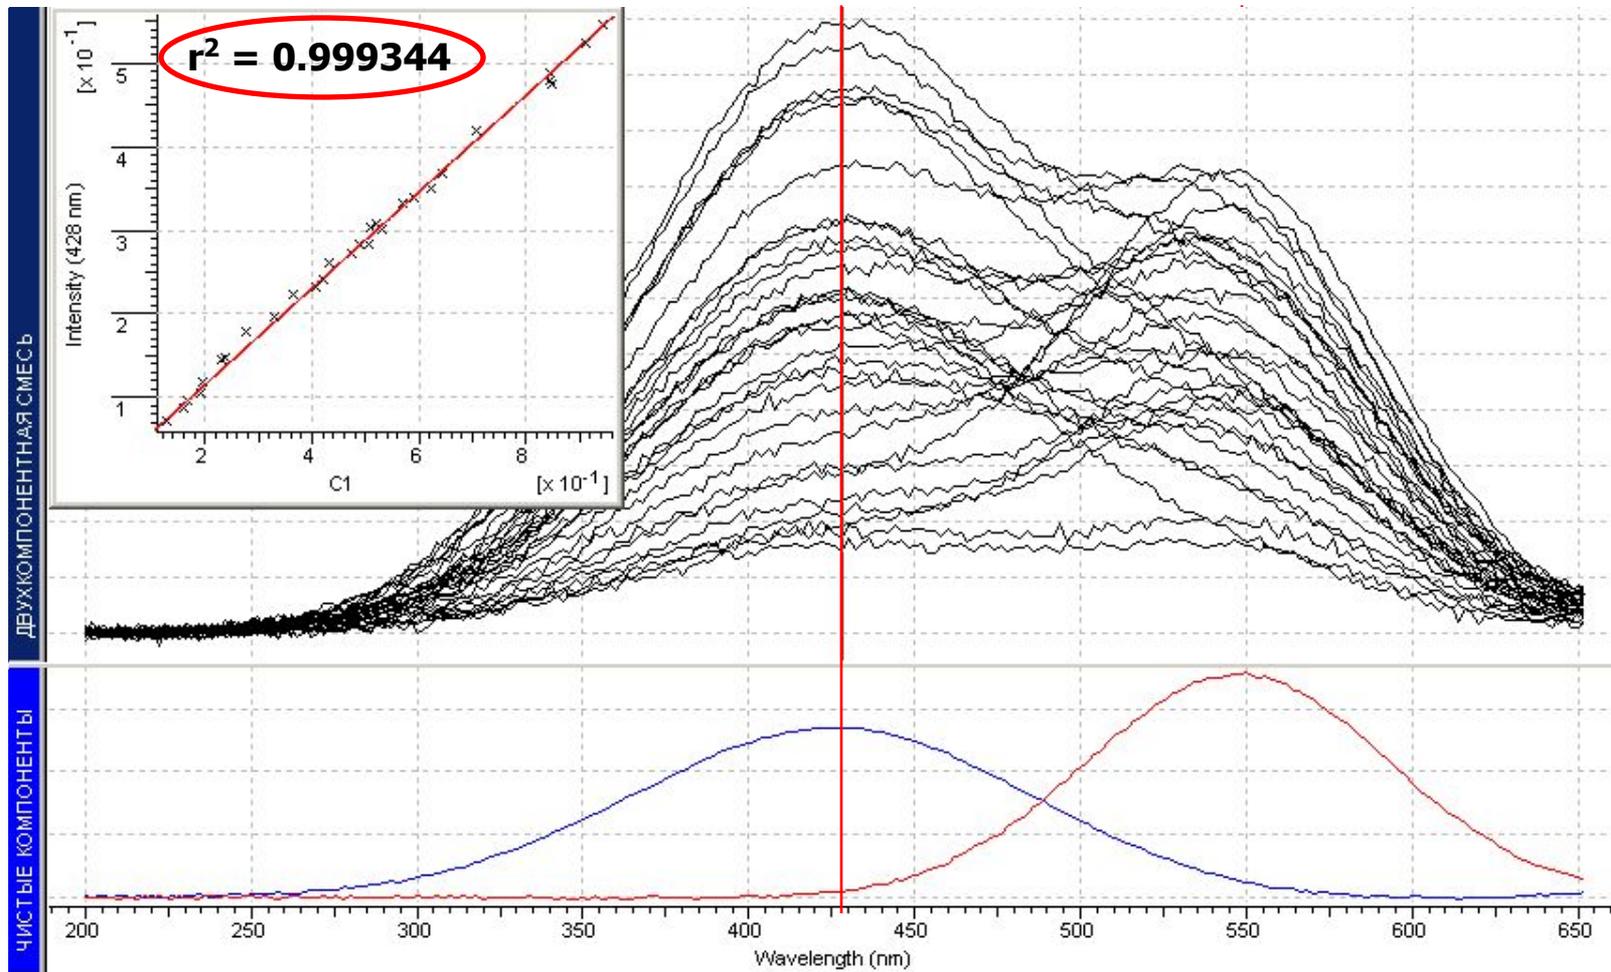
- **ХИМИЯ:** калибровка – инструмент №1 количественного анализа
- **БИОЛОГИЯ:** непосредственный анализ может быть губителен для живых существ
- **МЕДИЦИНА:** неинвазивный анализ, например, определение сахара в крови спектроскопически (ближний ИК)
- **ПСИХОЛОГИЯ:** анализ личности может потребовать длительных наблюдений, желательно использовать косвенные данные
- **СОЦИОЛОГИЯ и ФИНАНСЫ:** предсказание может быть основано только на исторических данных

Одномерная калибровка: ОДИН КОМПОНЕНТ

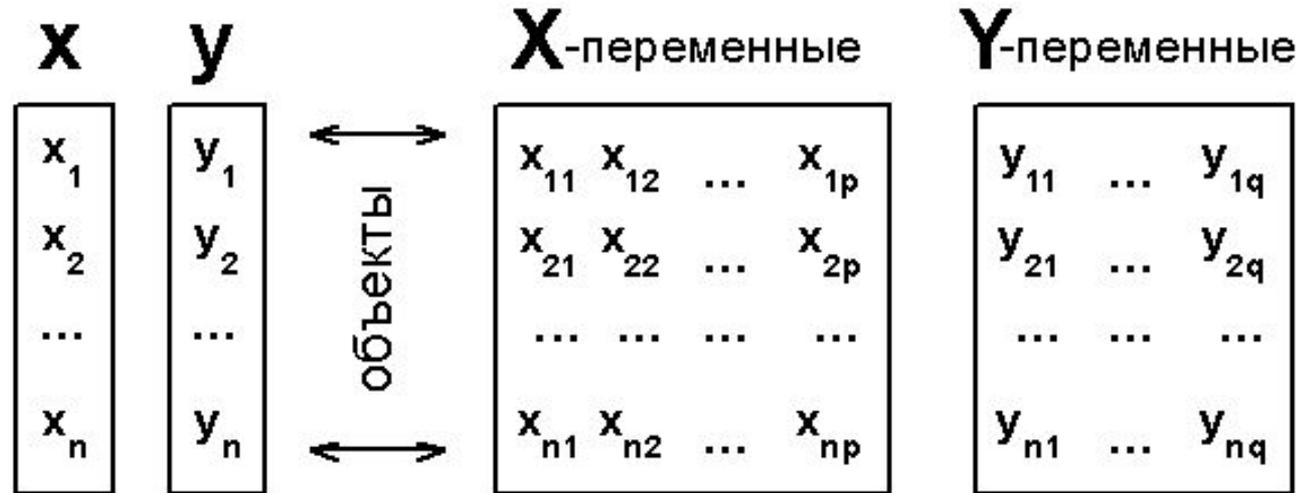
Univariate calibration



Одномерная калибровка: МНОГОКОМПОНЕНТНАЯ СМЕСЬ



Многомерная калибровка

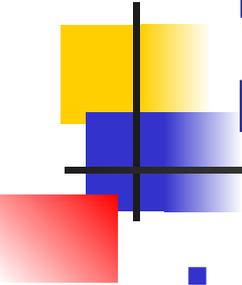


univariate
data

multivariate data

$$\mathbf{y} = \mathbf{x}\mathbf{b} + \mathbf{e}$$

$$\mathbf{Y} = \mathbf{X}\mathbf{B} + \mathbf{E}$$

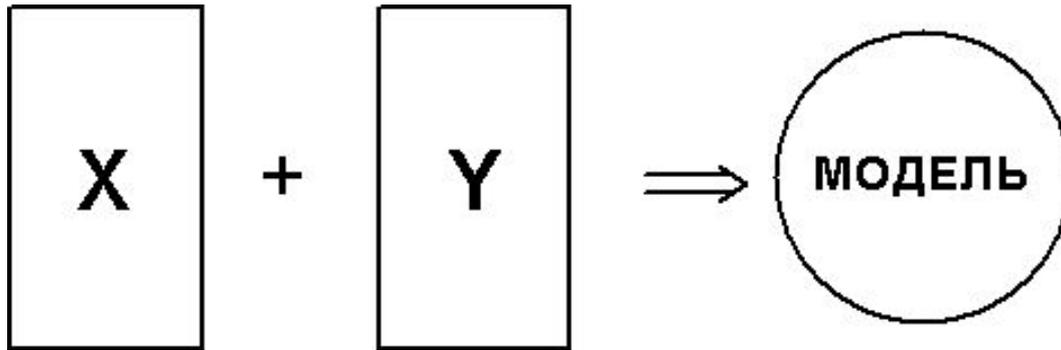


Преимущества многомерной калибровки


- возможность анализировать несколько компонентов одновременно
- выигрыш в точности от усреднения при использовании «избыточных», в т.ч. сильно коррелирующих измерений (спектры);
- возможность диагностики «плохих» образцов в процессе предсказания
- «парадигматический сдвиг» в подходах к решению проблем (например, NIR)

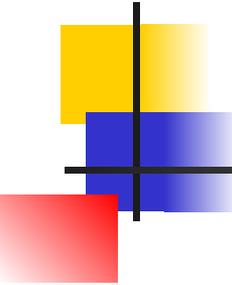
Калибровка и предсказание

Калибровка (Calibration)



Предсказание (Prediction)





Классические и инверсные методы

- Два основных подхода в многомерной калибровке:
- Классический МНК (**Classical Least Squares, CLS**) основан на прямом решении уравнения Бугера-Ламберта-Бера

$$\mathbf{A} = \mathbf{C}\boldsymbol{\varepsilon} \mid \mathbf{X} = \mathbf{Y}\boldsymbol{\varepsilon}$$

- Инверсный МНК (**Inverse Least Squares, ILS**) решают уравнение вида

$$\mathbf{C} = \mathbf{A}\mathbf{b} \mid \mathbf{Y} = \mathbf{X}\mathbf{b}$$

- В настоящей лекции – только ILS

Множественная линейная регрессия (МЛР)

Multiple Linear Regression (MLR)

$$y = b_0 + b_1 x_1 + b_2 x_2 + \dots + b_p x_p + e$$

$$y = X * b + e$$

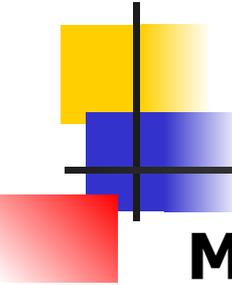
y_1	x_{11} ... x_{1p}	b_1	e_1
y_2	x_{21} ... x_{2p}	...	e_2
...	b_p	...
y_n	x_{n1} ... x_{np}		e_n

n - число объектов (спектров)

p - число переменных (длин волн)

$$n \geq p$$

Решение: $b = (X^T X)^{-1} X^T y$



Недостатки МЛР

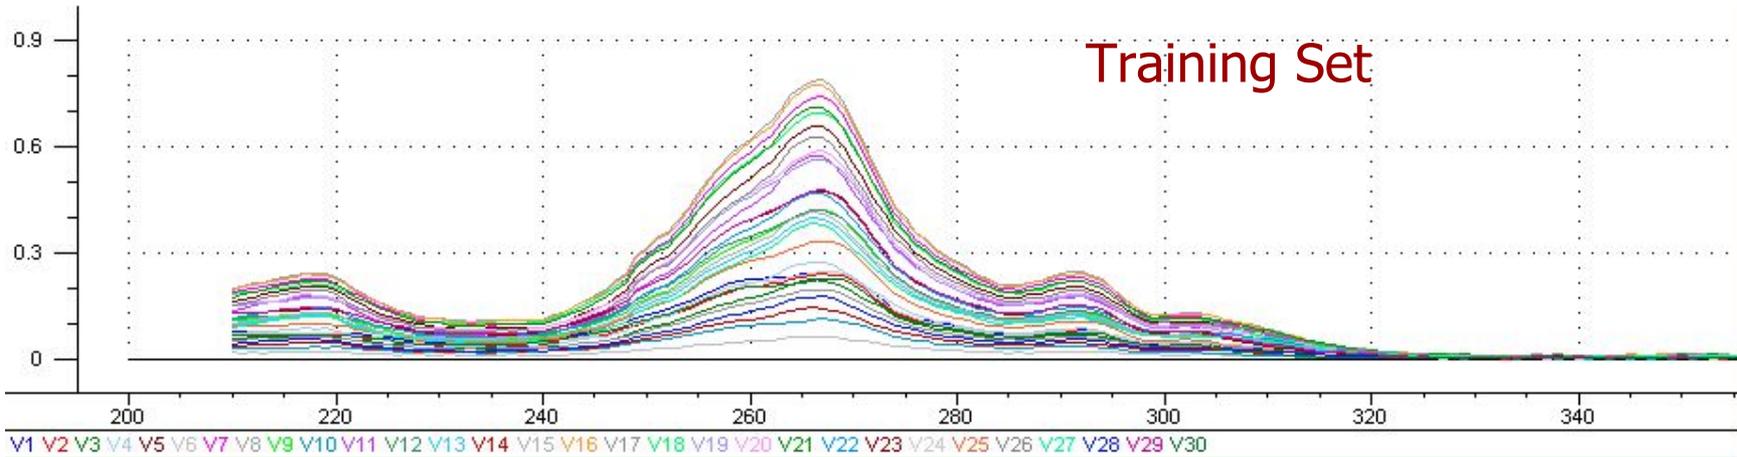
МЛР может не сработать, если:

- высока коллинеарность в \mathbf{X} (спектры)
- неустойчивое решение для коллинеарных данных обусловлено преобразованием $(\mathbf{X}^T \mathbf{X})^{-1} \mathbf{X}^T$
- высокий уровень шума, ошибки в \mathbf{X}
- переменных больше, чем образцов (типично для спектральных данных)
- есть линейная зависимость между переменными внутри \mathbf{X}
- визуальная интерпретация МЛР-моделей затруднительна

Пример спектральных данных: полиароматические углеводороды

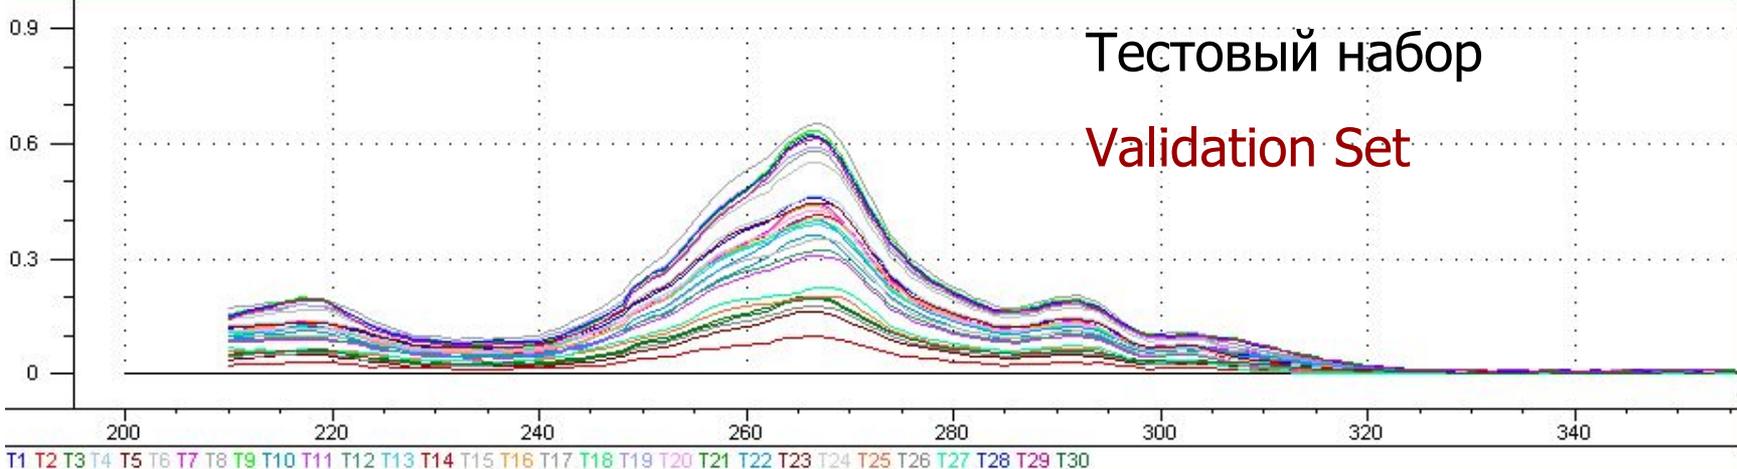
Обучающий набор

Training Set



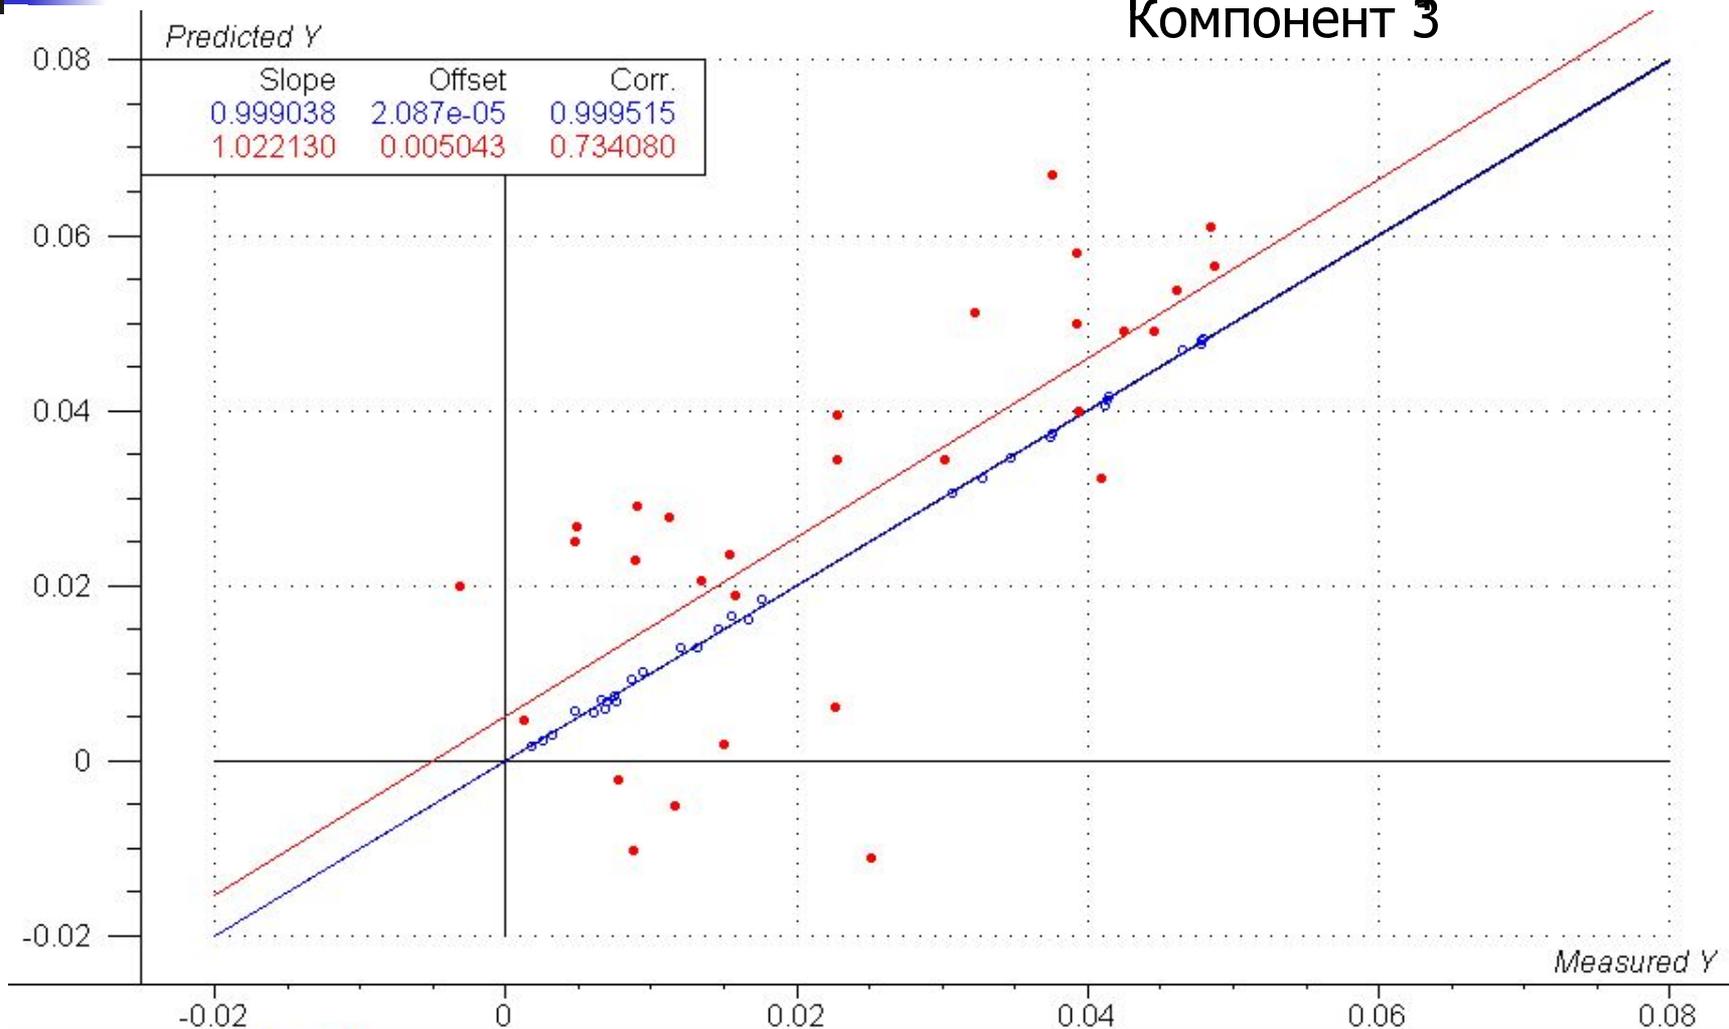
Тестовый набор

Validation Set



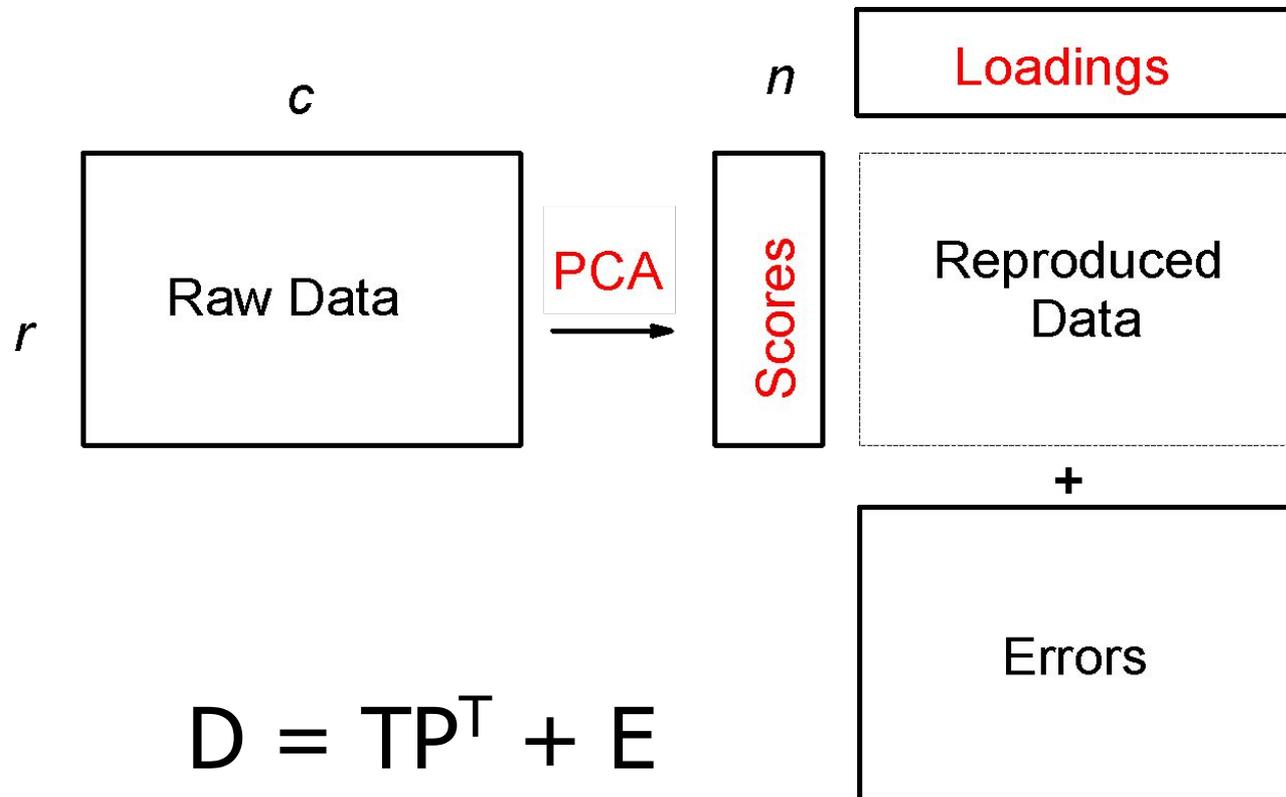
МЛР-калибровка

Компонент 3

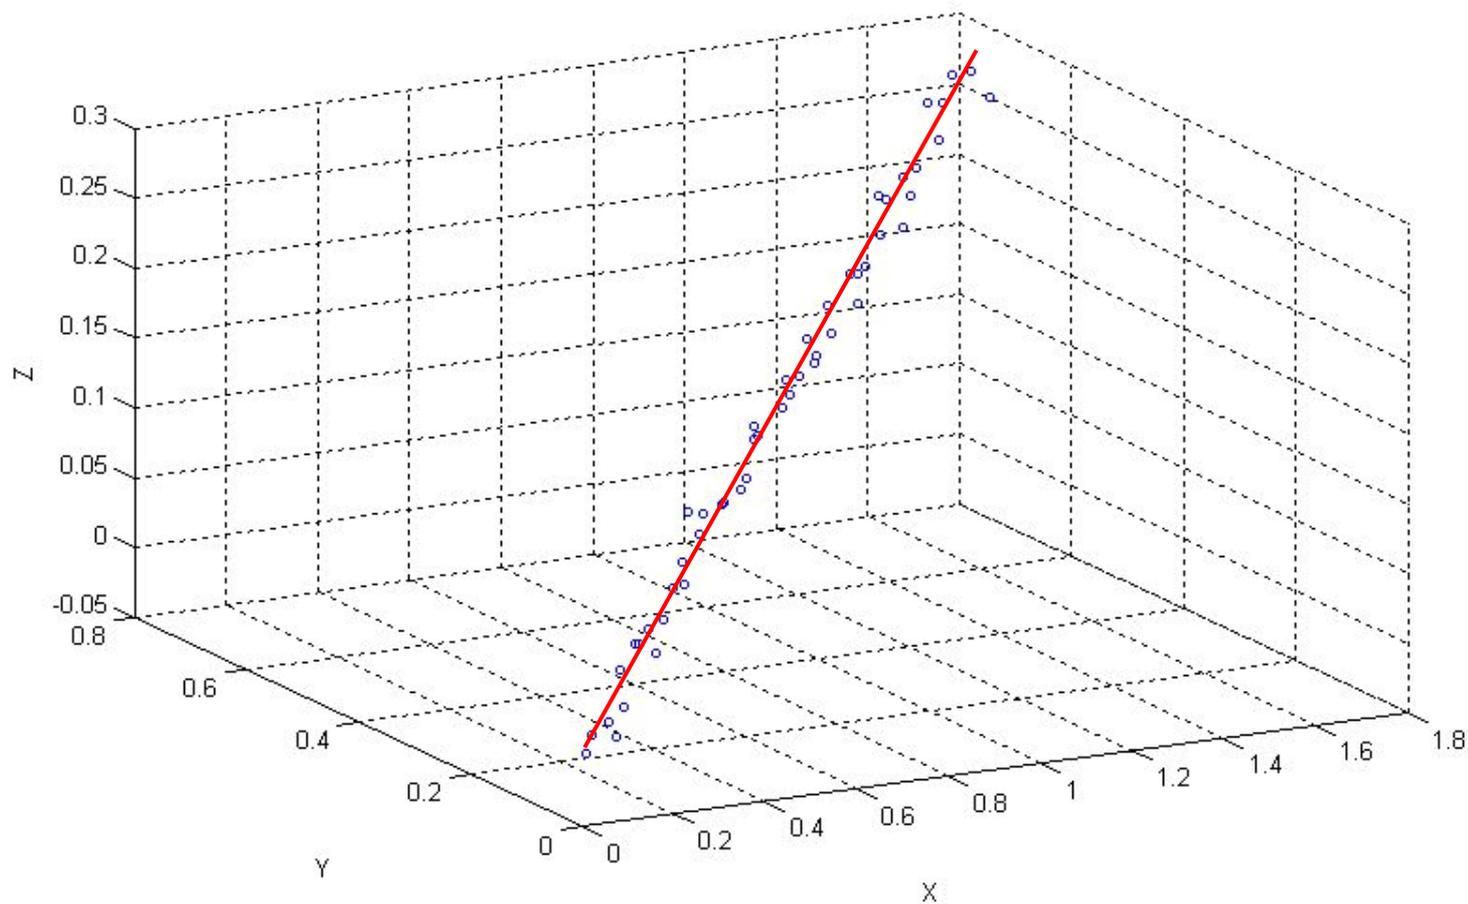


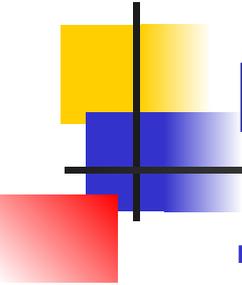
RESULT4, Y-var: [C3] [C3]

МГК (PCA) - оружие против коллинеарности



Концепция PCA «на пальцах»





PCA + MLR = PCR !

- В результате РГК (PCA):
 - Происходит компрессия данных
 - уменьшается размерность данных
 - коллинеарность обращается во благо;
 - уменьшается ошибка;
 - РГК-нагрузки (PCA-scores) T ортогональны
 - содержат информацию о концентрациях компонентов
- T можно использовать для построения MLR-модели, вместо **X**; этот метод называется...
- регрессия на главные компоненты, РГК (Principal Component Regression, PCR)

Схема РГК (PCR) – подробнее

PCA:

$$X = T * P^T + E$$

x_{11}	...	x_{1p}
x_{21}	...	x_{2p}
...
x_{n1}	...	x_{np}

t_{11}	...	t_{1a}
t_{21}	...	t_{2a}
...
t_{n1}	...	t_{na}

p_{11}	p_{12}	...	p_{1p}
...
p_{a1}	p_{a2}	...	p_{ap}

e_{11}	...	e_{1p}
e_{21}	...	e_{2p}
...
e_{n1}	...	e_{np}

MLR:

$$y = \downarrow T * b + e$$

y_1
y_2
...
y_n

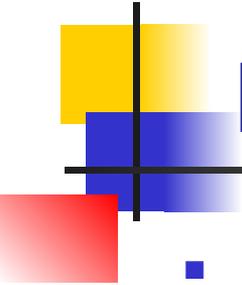
t_{11}	...	t_{1a}
t_{21}	...	t_{2a}
...
t_{n1}	...	t_{na}

b_1
...
b_a

e_1
e_2
...
e_n

n - объектов
 p - переменных
 a - главных
 КОМПОНЕНТ

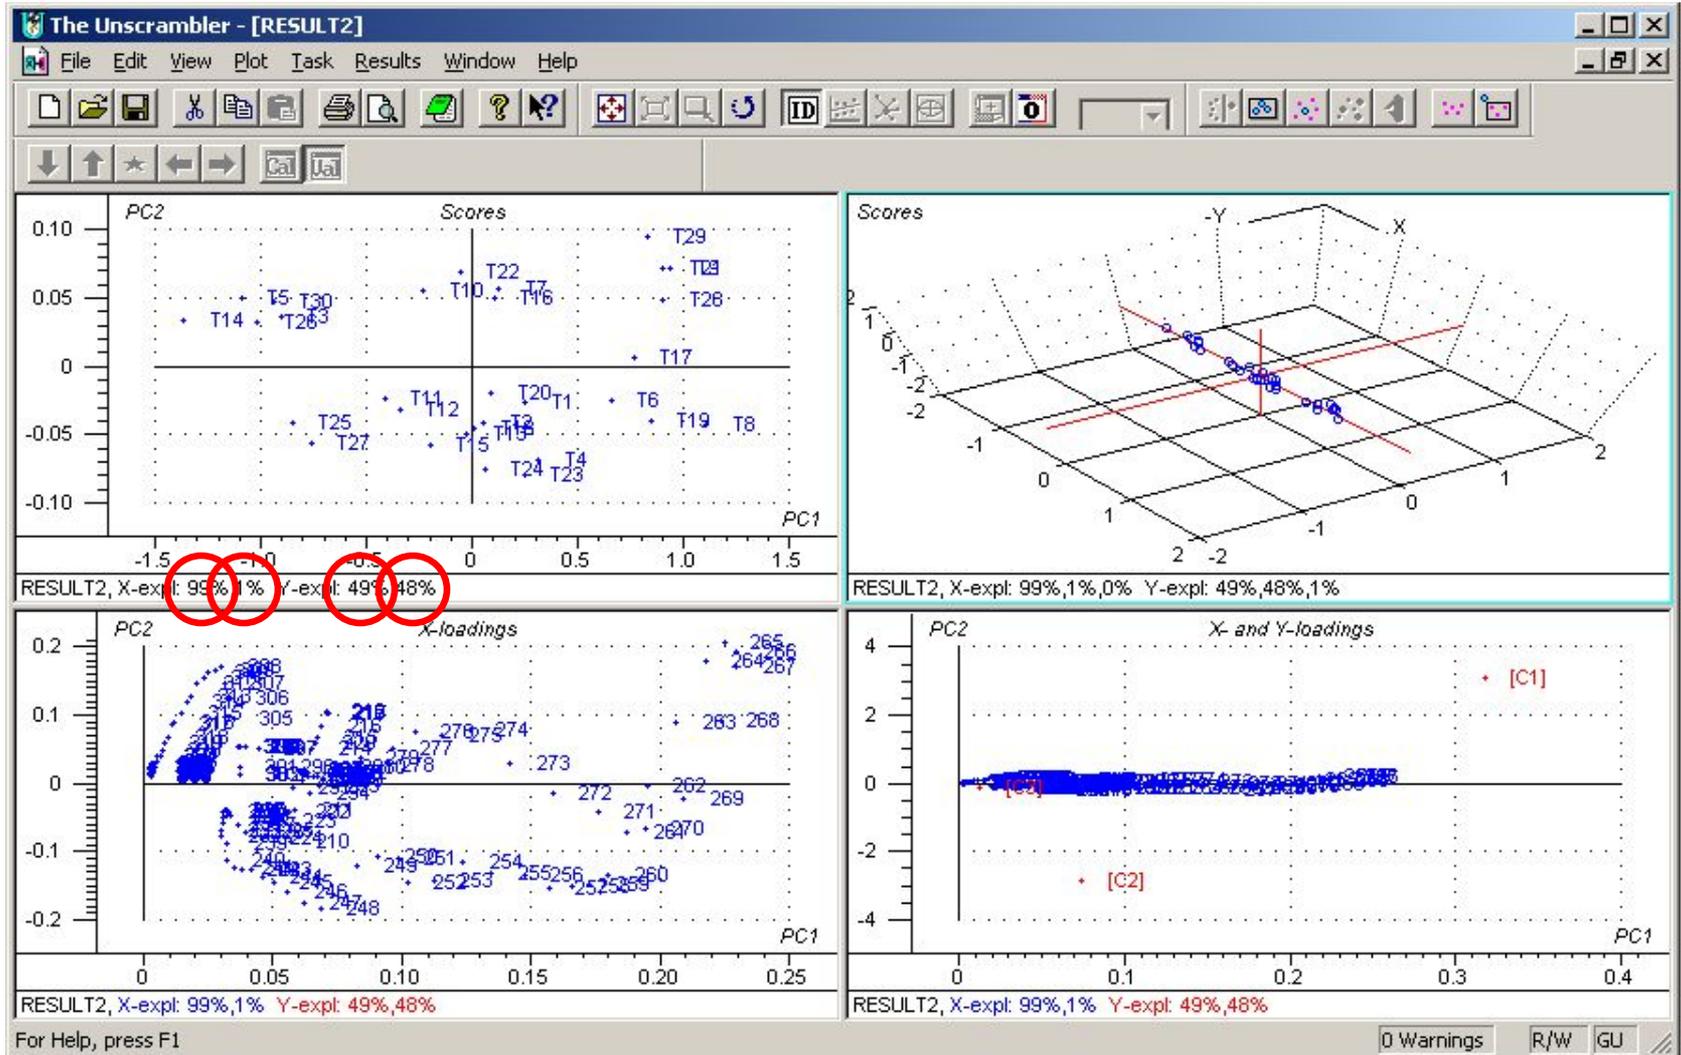
$$a \leq \min(n, p)$$

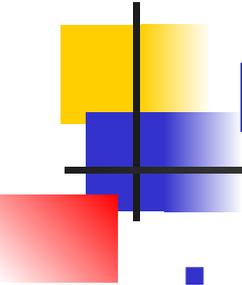


Интерпретация РГК-модели

- интерпретация модели служит для изучения внутренней структуры данных:
 - Группы
 - Выбросы
 - Связь между X и Y
- инструменты диагностики МГК (PCA) работают в РГК (PCR):
 - График счетов (Scores)
 - График нагрузок (Loadings)
 - График счетов и нагрузок вместе (Bi-plot)
 - График остатков (Residuals)
- инструменты диагностики РГК:
 - Совместный график нагрузок X и Y

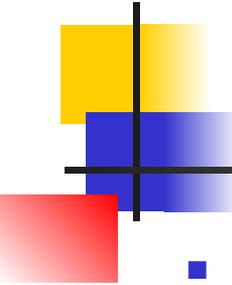
Строим РГК-модель (Simdata)





Проверка (валидация) модели

- проверка (**Validation**) модели служит для:
 - Определения размерности модели (числа ГК)
 - Оценки предсказательной способности модели
- проверка модели производится с помощью тестовых данных:
 - того же диапазона и того же качества что обучающие данные (та же генеральная выборка)
 - достаточно представительные
- или кросс-валидации (**Cross-Validation**)
 - Полная
 - Сегментная



RMSEP

- **RMSEC** = Root Mean Square Error of Calibration


$$RMSEC = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_{i,cal} - y_{i,cal})^2}{n}}$$

- **RMSEP** = Root Mean Square Error of Prediction

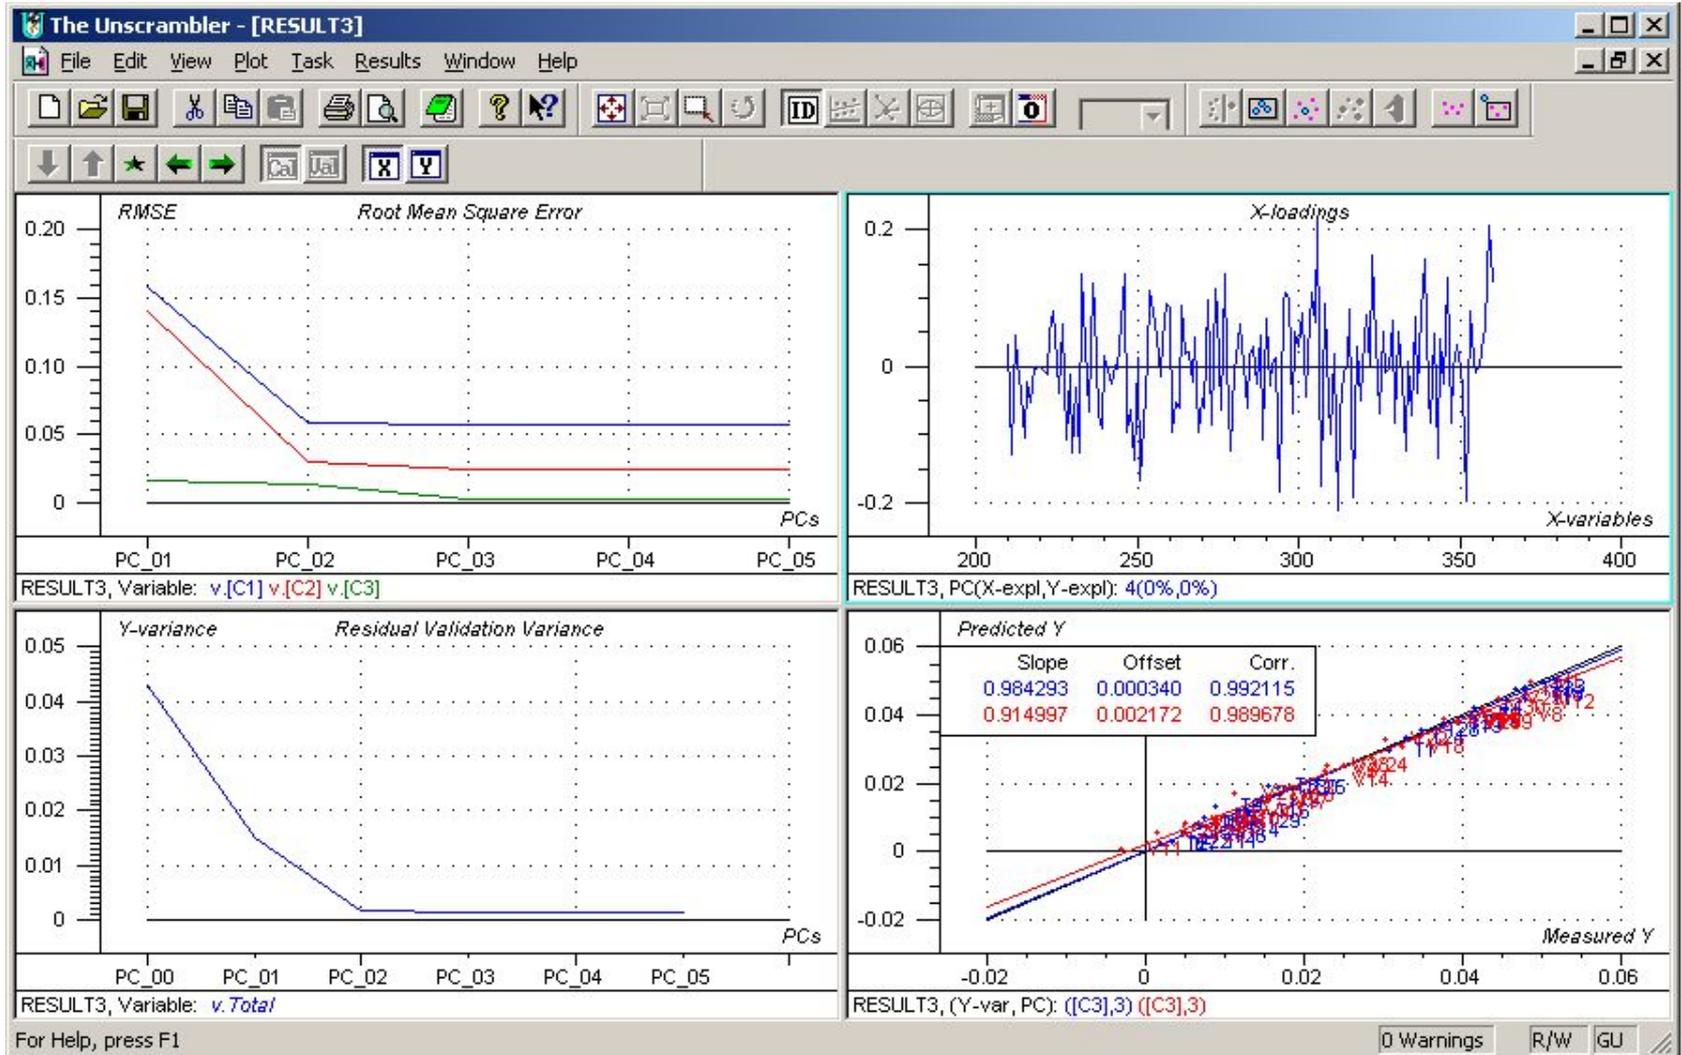
$$RMSEP = \sqrt{\frac{\sum_{i=1}^n (\hat{y}_{i,val} - y_{i,val})^2}{n}}$$

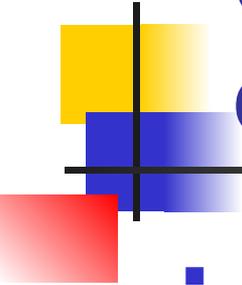
- МИНИМУМ на кривой RMSEP - основной индикатор числа ГК
- RMSEP - оценка точности в единицах измерения!
- RMSEP используется для сравнения моделей

Оценка числа компонент в РГК



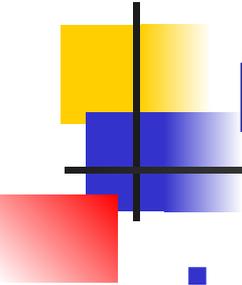
Число компонент (Simdata)





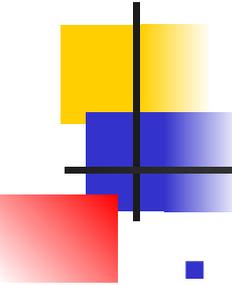
Оценка числа ГК в РГК: особенности

- число ГК (размерность модели) определяется нуждами калибровки, и не обязательно совпадает с результатом МГК
- активно используется тестовые данные (**Test Set**)
- **RMSEP** = Root Mean Square Error of Prediction
- минимум на кривой RMSEP - основной индикатор числа ГК
- для спектральных данных показательной может быть форма X-нагрузок (**X-loadings**)
- решение всегда за экспертом!



Несовершенства РГК

- РГК - мощный метод многомерной калибровки
- имеет безусловные преимущества перед MLR
- однако, не вполне оптимизирован для калибровки
- пространство ГК оптимально для моделирования внутренней структуры данных матрицы \mathbf{X} , но не учитывает структуры \mathbf{Y} и связи между \mathbf{X} и \mathbf{Y}
- можно ли учесть эту связь при построении проекционной модели?
- да, использовать PLS!

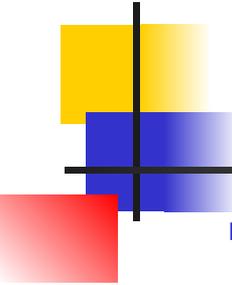


Факторные пространства

- существует бесконечное множество способов декомпозиции данных вида

$$\mathbf{D} = \mathbf{T}\mathbf{P}^T + \mathbf{E}$$

- парные вектора в \mathbf{T} и \mathbf{P} называются факторами (**factors**), а преобразование - проекцией данных на факторное пространство (**factor space**) или факторной компрессией
- пространство главных компонент один из наиболее важных вариантов факторного пространства
- для задания факторного пространства нужен критерий, например, МГК (**PCA**) использует критерий максимальной остаточной дисперсии

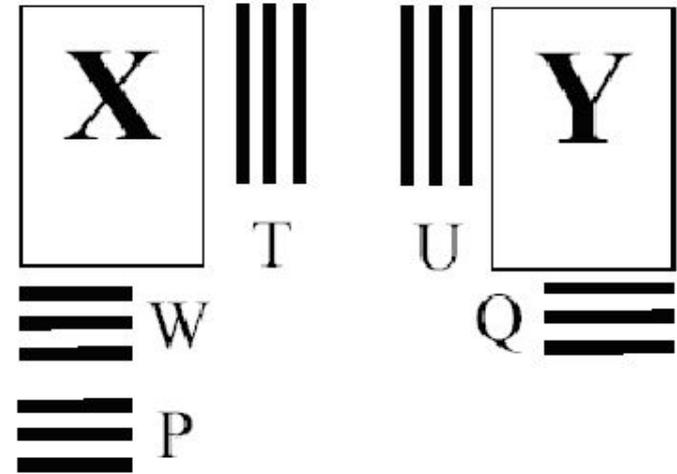


PLS – мощная альтернатива PCR

- Метод проекции на латентные структуры (ПЛС) и ПЛС-регрессия (ПЛС-Р)
 - PLS = Partial Least Squares ->
 - Projection on Latent Structures
- ПЛС-пространство создается при участии двух переменных **X** и **Y** одновременно; критерием является моделирование той структуры (информации) в **X**, которая имеет корреляцию с **Y**
- например, спектральные полосы (**X**), которые отвечают за концентрацию компонента(ов), заданные в **Y**
- ПЛС-модель специально оптимизирована для регрессионного анализа

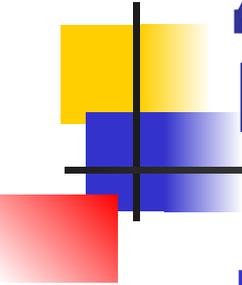
ПЛС-регрессия: схематическое представление

- ПЛС-декомпозиция затрагивает обе матрицы **X** и **Y**
- в результате - 2 набора счетов (**scores**) и нагрузок (**loadings**)
- плюс дополнительная матрица взвешенных нагрузок **W** (**loading-weights**)
- критерий: максимальная ковариация между **T** и **U**



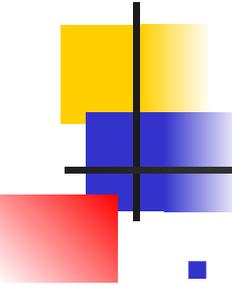
$$\mathbf{X} = \mathbf{TP}^T + \mathbf{E}$$

$$\mathbf{Y} = \mathbf{UQ}^T + \mathbf{F}$$



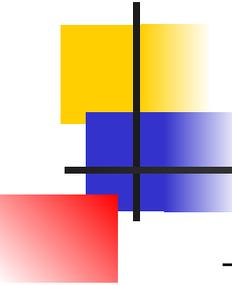
Две разновидности ПЛС: ПЛС1 и ПЛС2

- существуют две популярных разновидности ПЛС: ПЛС1 (**PLS1**) и ПЛС2 (**PLS2**)
- ПЛС1 модель строится для единственной переменной Y (аналогия с МЛР), например, для концентрации одного компонента смеси
- если нужна калибровка по нескольким компонентам, строится несколько независимых моделей
- ПЛС2 рассчитывается для нескольких компонентов одновременно
- расчетные алгоритмы методов отличаются соответственно



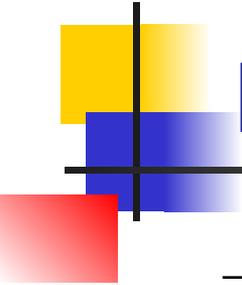
Основы алгоритма ПЛС

- ПЛС-декомпозиция производится алгоритмом NIPALS
- **NIPALS** = Non-linear Iterative Partial Least Squares
- факторы находятся по очереди, один за другим, расчет всех факторов (как в SVD) не обязателен
- итерационная замена векторов $\mathbf{u}_f \rightarrow \mathbf{t}_f$ и $\mathbf{u}_f \rightarrow \mathbf{t}_f$ для нахождения текущего фактора f - алгоритмическая основа ПЛС
- алгоритм работает до выполнения критерия сходимости
- детальное изучение алгоритмов не входит в задачу данной лекции, однако...
- ознакомимся с основными шагами на примере ПЛС2



NIPALS алгоритм для ПЛС2

- | | | |
|----|--|--|
| 0. | \mathbf{u}_f | выбор начального приближения \mathbf{u} |
| 1. | $\mathbf{w}_f = \mathbf{X}_f^T \mathbf{u}_f / \mathbf{X}_f^T \mathbf{u}_f $ | расчет нормализованного вектора взвешенных нагрузок \mathbf{w} |
| 2. | $\mathbf{t}_f = \mathbf{X}_f^T \mathbf{w}_f$ | расчет вектора весов \mathbf{t} |
| 3. | $\mathbf{q}_f = \mathbf{Y}_f^T \mathbf{t}_f / \mathbf{Y}_f^T \mathbf{t}_f $ | расчет нормализованного вектора нагрузок \mathbf{q} |
| 4. | $\mathbf{u}_f = \mathbf{Y}_f^T \mathbf{q}_f$ | расчет вектора счетов \mathbf{u} |
| 5. | $ \mathbf{t}_{f.new} - \mathbf{t}_{f.old} < \text{lim?}$ | проверка сходимости: да -> go to 1. |
| 6. | $\mathbf{p}_f = \mathbf{X}_f^T \mathbf{t}_f / \mathbf{t}_f^T \mathbf{t}_f$ | расчет вектора весов \mathbf{p} |
| 7. | $b_f = \mathbf{u}_f^T \mathbf{t}_f / \mathbf{t}_f^T \mathbf{t}_f$ | расчет внутреннего коэффициента регрессии b |
| 8. | $\mathbf{X}_{f+1} = \mathbf{X}_{f+1} - \mathbf{t}_f^T \mathbf{p}_f$
$\mathbf{Y}_{f+1} = \mathbf{Y}_{f+1} - b_f \mathbf{t}_f \mathbf{q}_f^T$ | расчет остатка \mathbf{X} и \mathbf{Y} |
| 9. | $f = f + 1$ | Переход к следующему фактору |



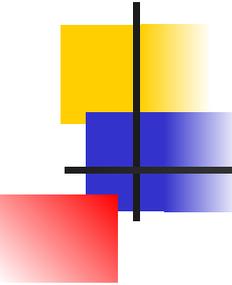
NIPALS алгоритм для ПЛС1

-
1. $\mathbf{w}_f = \mathbf{X}_f^T \mathbf{y}_f / |\mathbf{X}_f^T \mathbf{y}_f|$ расчет нормализованного вектора взвешенных нагрузок \mathbf{w}
 2. $\mathbf{t}_f = \mathbf{X}_f^T \mathbf{w}_f$ расчет вектора весов \mathbf{t}
 3. $q_f = \mathbf{y}_f^T \mathbf{t}_f / |\mathbf{t}_f^T \mathbf{t}_f|$ расчет нагрузки q (скаляр) фактора f
-

-
4. $\mathbf{p}_f = \mathbf{X}_f^T \mathbf{t}_f / \mathbf{t}_f^T \mathbf{t}_f$ расчет вектора весов \mathbf{p}
-

-
5. $\mathbf{X}_{f+1} = \mathbf{X}_{f+1} - \mathbf{t}_f^T \mathbf{p}_f$ расчет остатка \mathbf{X} и \mathbf{y}
 $\mathbf{y}_{f+1} = \mathbf{y}_{f+1} - q_f \mathbf{t}_f$
-

6. $f = f + 1$ переход к следующему фактору



NIPALS алгоритм для ПЛС1

1. $\mathbf{w}_f = \mathbf{X}_f^T \mathbf{y}_f / |\mathbf{X}_f^T \mathbf{y}_f|$ расчет нормализованного вектора взвешенных нагрузок \mathbf{w}

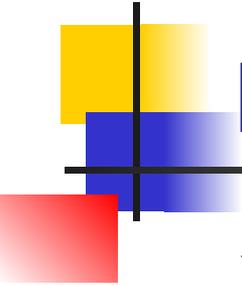
2. $\mathbf{t}_f = \mathbf{X}_f^T \mathbf{w}_f$ расчет вектора весов \mathbf{t}

3. $q_f = \mathbf{y}_f^T \mathbf{t}_f / |\mathbf{t}_f^T \mathbf{t}_f|$ расчет нагрузки q (скаляр) фактора f

4. $\mathbf{p}_f = \mathbf{X}_f^T \mathbf{t}_f / \mathbf{t}_f^T \mathbf{t}_f$ расчет вектора весов \mathbf{p}

5. $\mathbf{X}_{f+1} = \mathbf{X}_{f+1} - \mathbf{t}_f^T \mathbf{p}_f$
 $\mathbf{y}_{f+1} = \mathbf{y}_{f+1} - q_f \mathbf{t}_f$ расчет остатка \mathbf{X} и \mathbf{y}

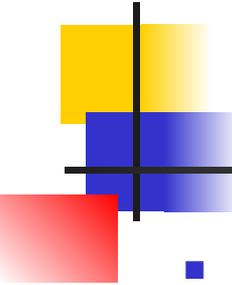
6. $f = f + 1$ переход к следующему фактору



Предсказание по ПЛС-модели

$$\hat{\mathbf{Y}} = \mathbf{X}_{\text{new}} \mathbf{B}$$

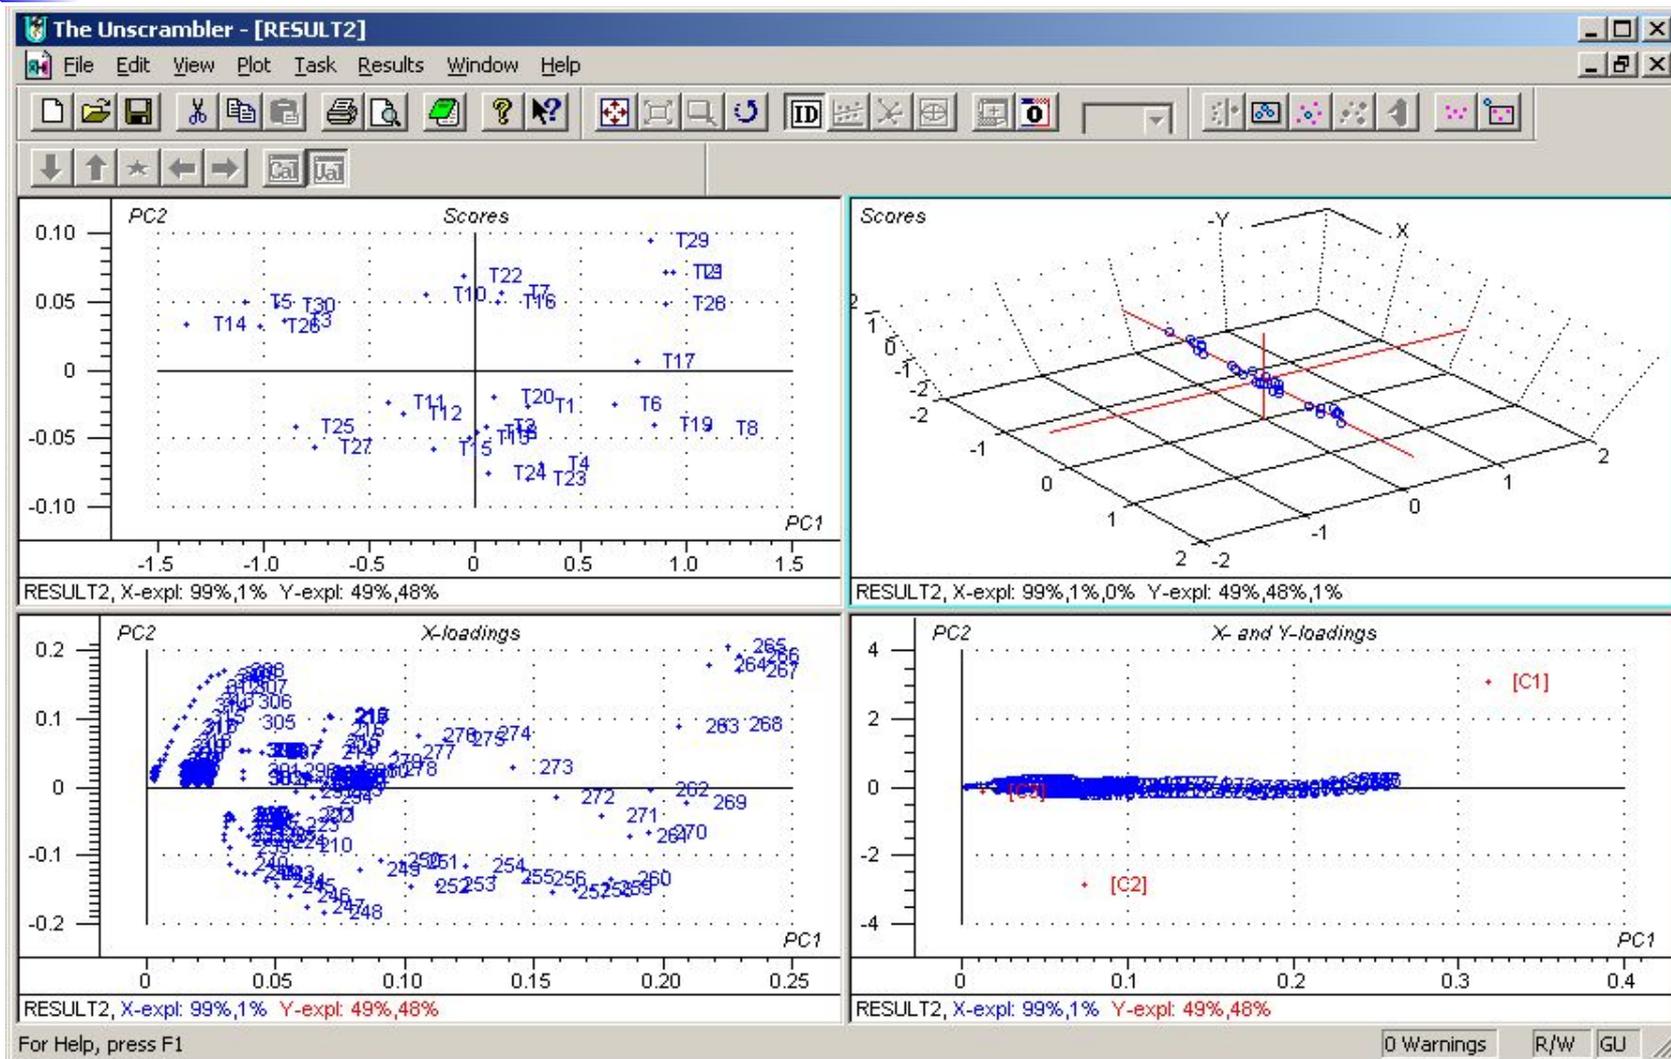
$$\mathbf{B} = \mathbf{W}(\mathbf{P}^T \mathbf{W})^{-1} \mathbf{Q}^T$$



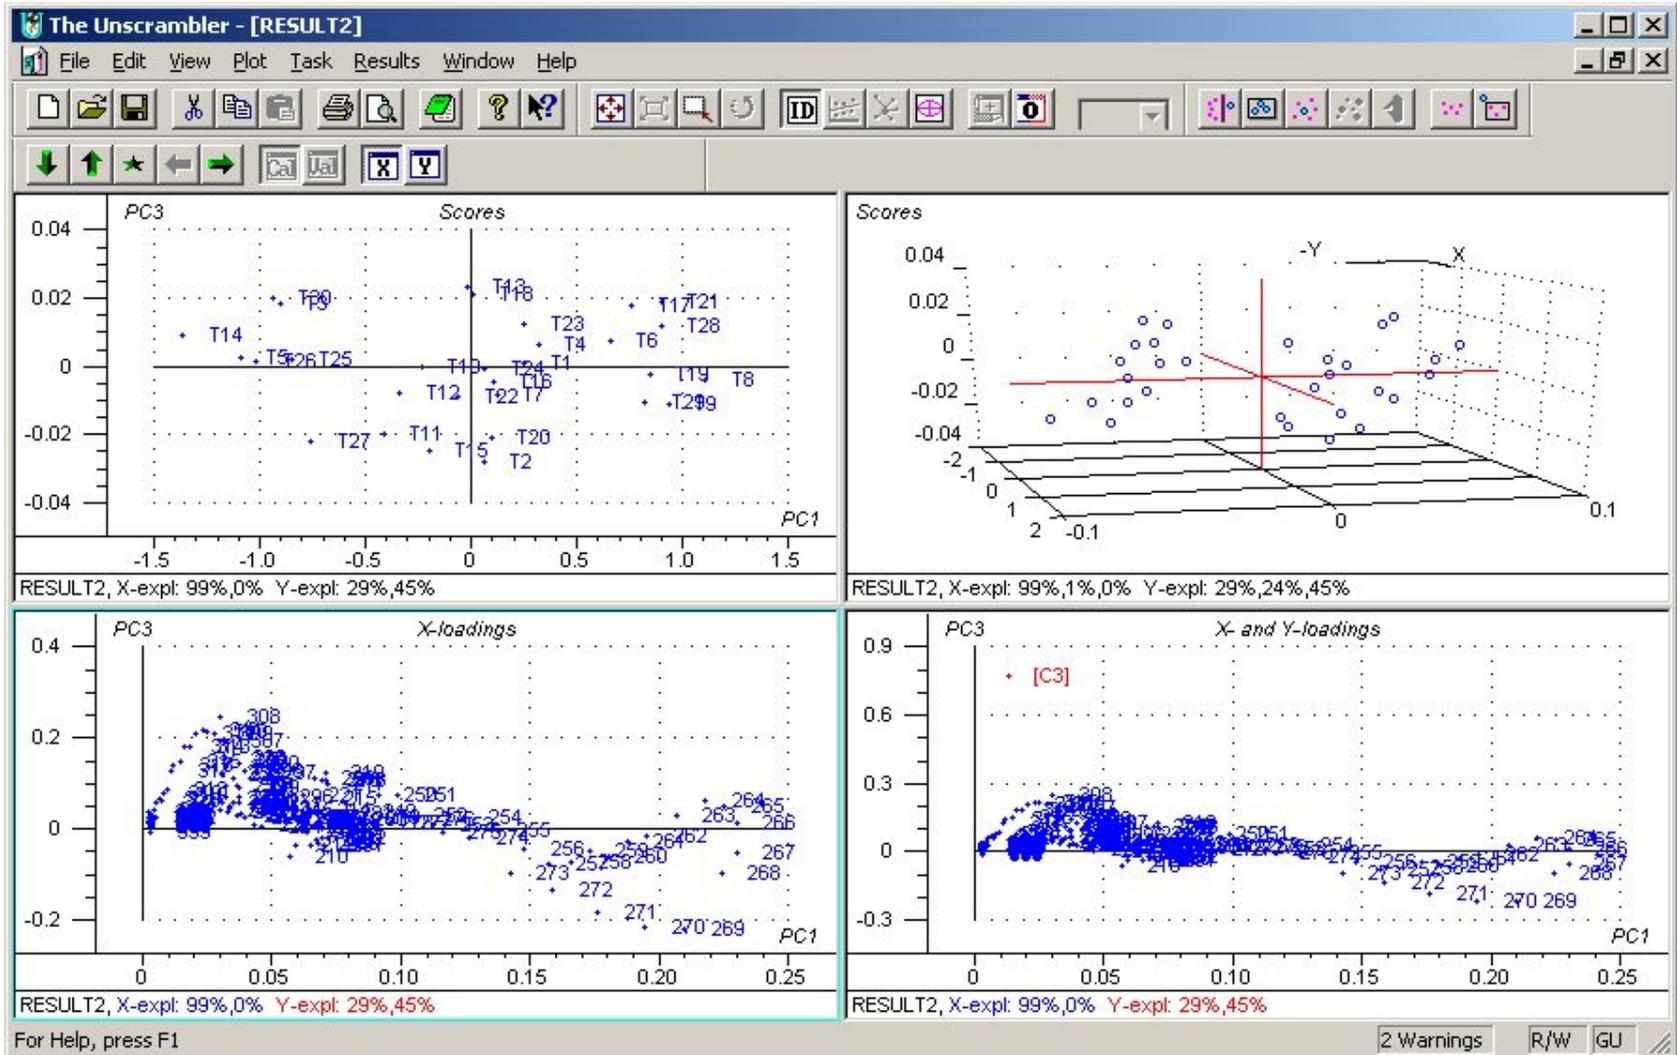
ПЛС1 и ПЛС2

- ПЛС1 моделирует только одну переменную y «за раз»
- в этом смысле ПЛС2 кажется гибче при калибровке нескольких свойств, позволяя моделировать любую комбинацию переменных без их разделения - совместно
- однако, ПЛС1 дает по отдельной модели на каждое из интересующих свойств, возможно, с различным числом факторов
- не будет ли набор независимых моделей всегда лучшим решением?
- однозначного ответа пока нет...
- сравним методы на практике!

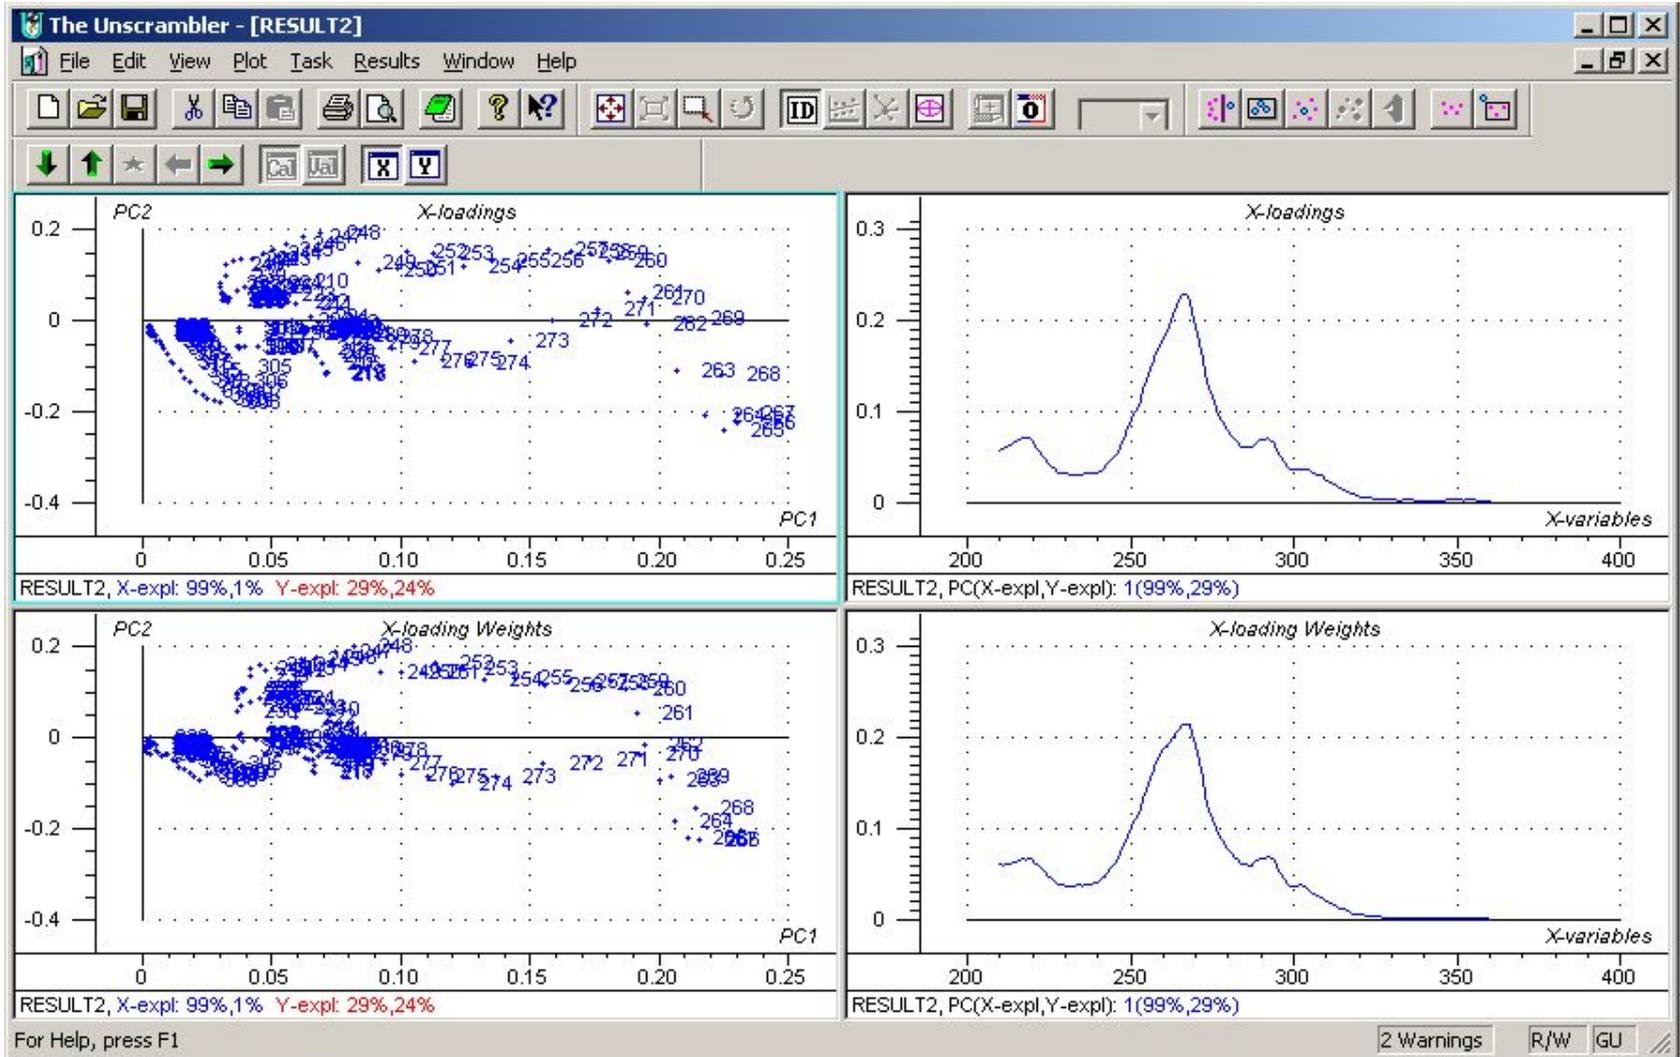
Строим ПЛС2-модель (Simdata)



Интерпретация ПЛС-моделей структура X (Simdata)

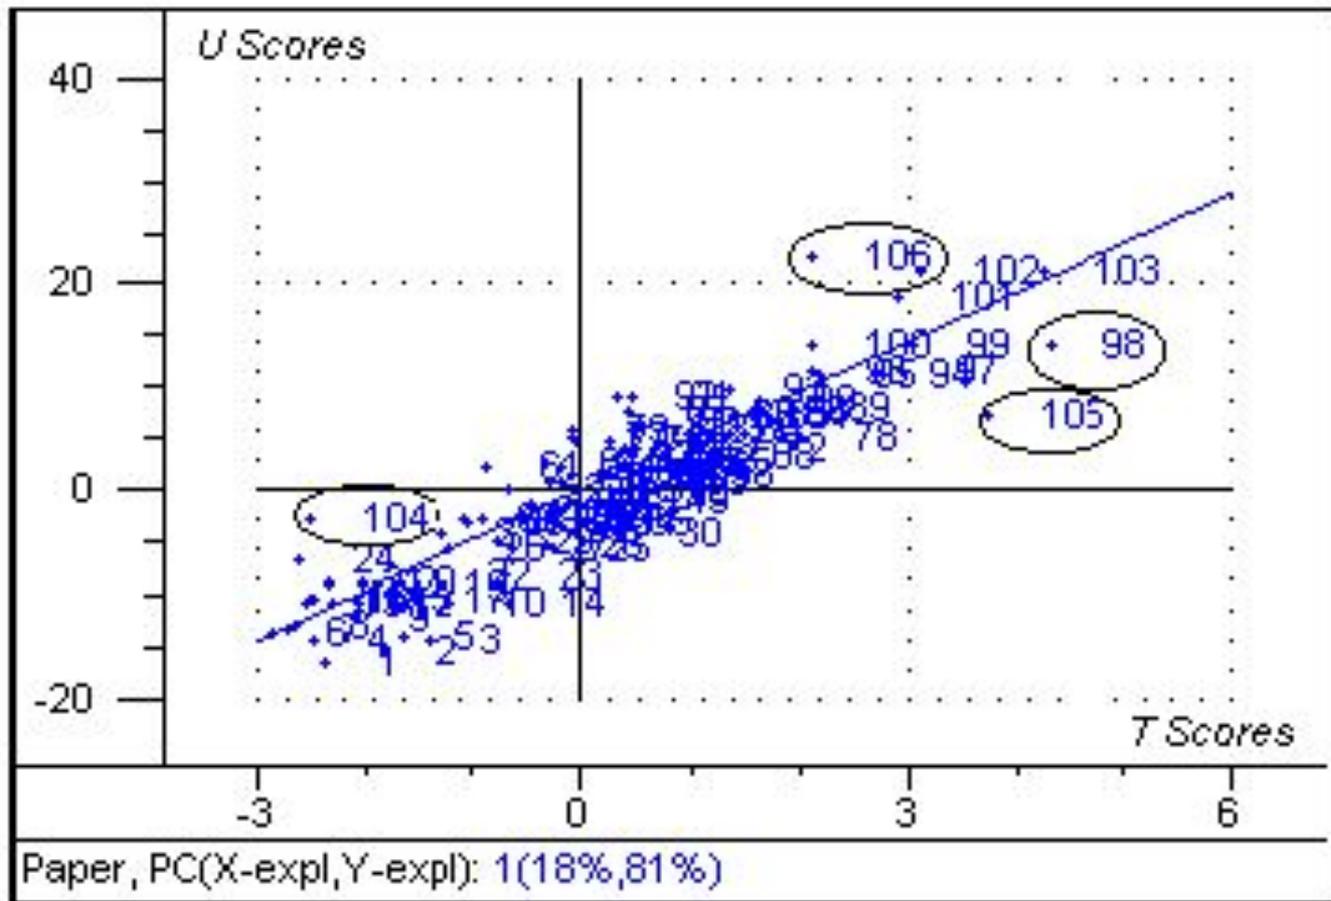


Интерпретация ПЛС-моделей: связь X и Y (Simdata)

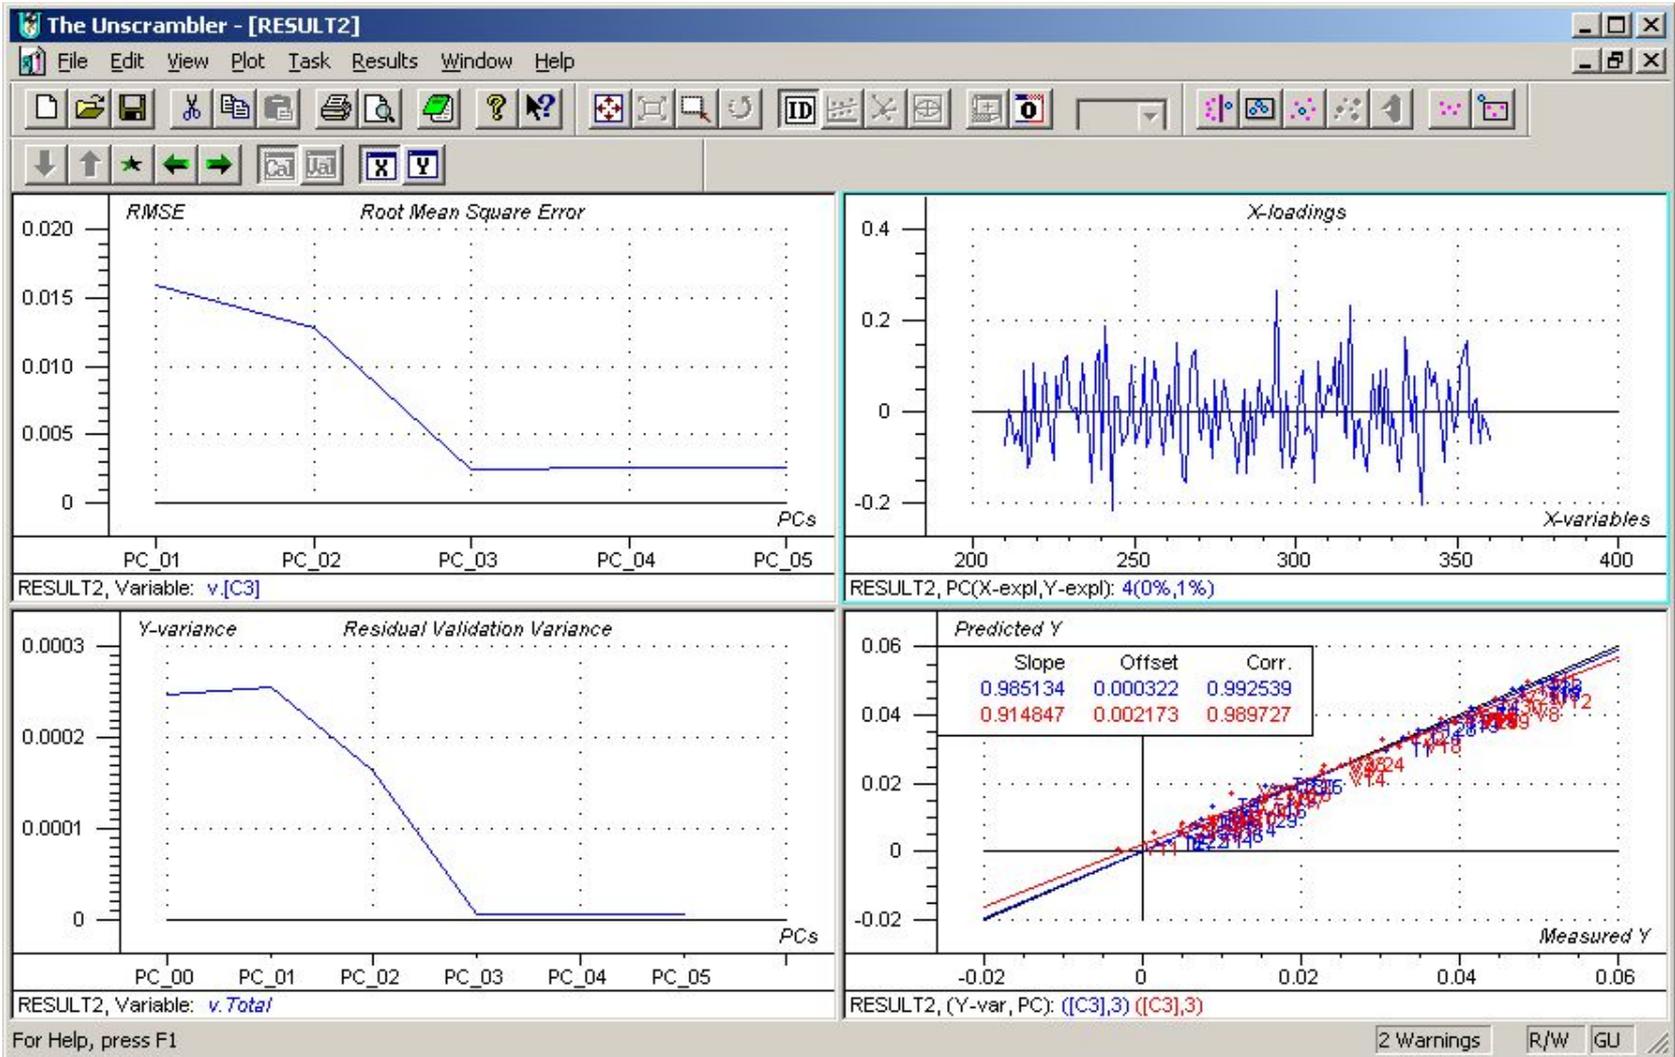


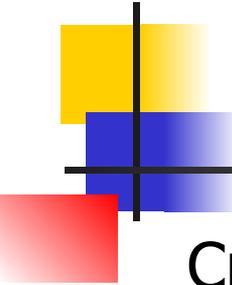
Интерпретация ПЛС-модели: выбросы (Octane)

График T - U как средство детекции выбросов (**outliers**)



Проверка ПЛС-моделей



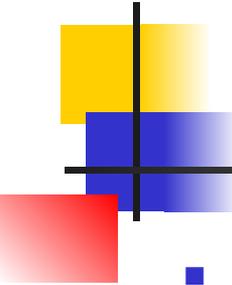


Сравнение моделей (Simdata)

Сравнение моделей калибровки
трехкомпонентной смеси ПАУ (Simdata)

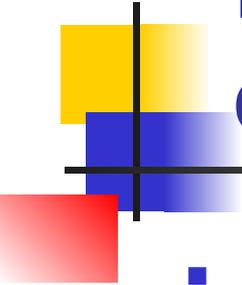
	МЛР (MLR)	РГК (PCR)	ПЛС1-Р (PLS1-R)	ПЛС2-Р (PLS2-R)
[C1]	0.1312	0.0576	0.0575	0.0575
[C2]	0.0527	0.0241	0.0245	0.0245
[C3]	0.01579	0.00246	0.00246	0.00249

- вывод: модели РГК, ПЛС1-Р, ПЛС2-Р примерно одинаково хороши для калибровки этих данных (без осложнений)
- результаты МЛР значительно хуже, для [C3] - неудовлетворительные



Сравнение методов калибровки

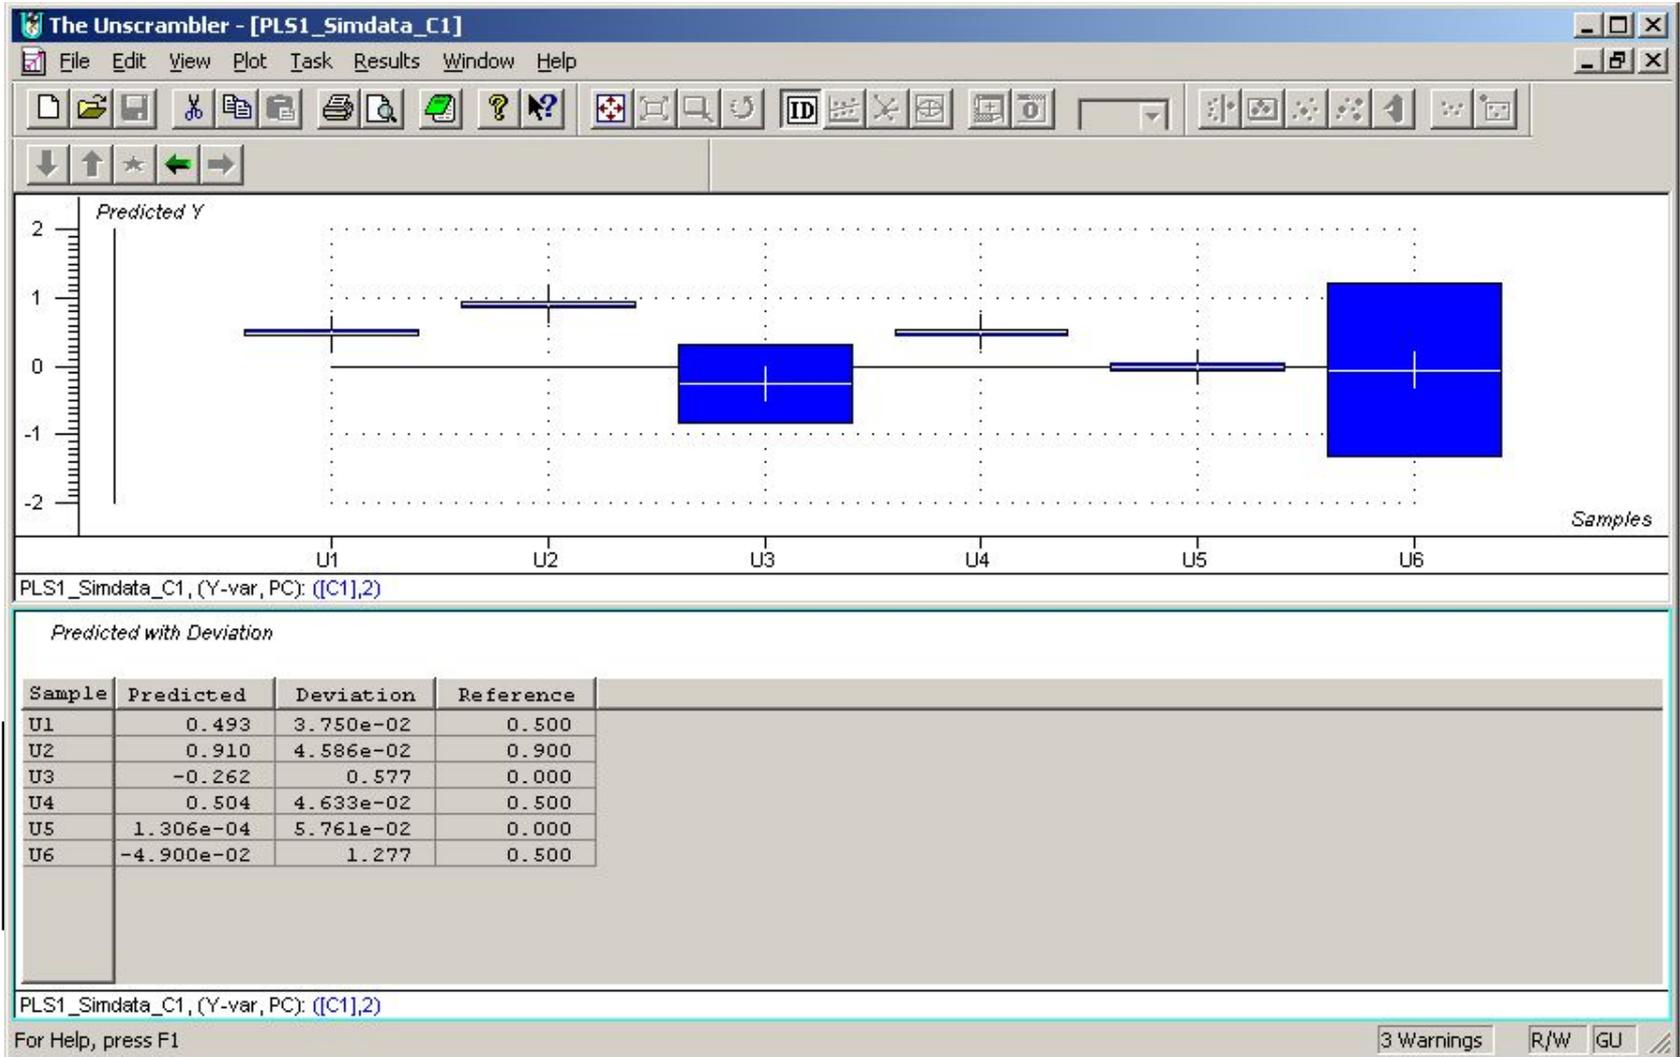
- MLR плохо пригоден для спектроскопических данных
- PCR имеет недостатки, но хорошо работает при отсутствии осложнений
- PLS является лучшим решением для большинства практических задач
- PLS1 или PLS2?
- Как выбрать метод? – пробовать!
- Как сравнивать разные модели? RMSEP

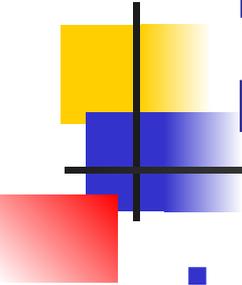


Предсказание: диагностика соответствия новых образцов

- с построением калибровочной модели проблемы еще не кончаются
- возможность выявления образцов, несоответствующих данной регрессионной модели является одним из преимуществ многомерного подхода в калибровке
- **Deviation** - эмпирический параметр, характеризующий меру соответствия нового образца калибровочной модели
- рассмотрим наш пример...

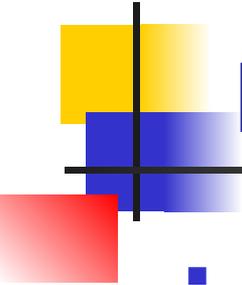
Диагностика предсказания (Simdata)





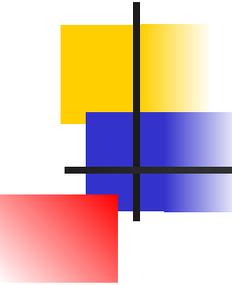
Принципы построения «хорошей» калибровки

- правильно приготовить (собрать) образцы
- визуально изучить данные, если необходимо, применить предварительную обработку данных (**preprocessing**)
- если необходимо применить шкалирование/взвешивание (**scaling/weighting**)
- интерпретировать модель, изучить структуру данных, выявить и удалить возможные выбросы
- тщательно оценить размерность модели, диагностировать модель
- диагностировать предсказание



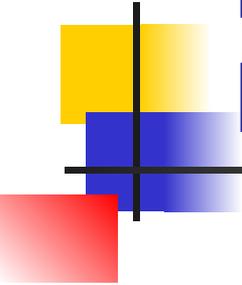
План семинара

- Пример 1. Концентрационная калибровка трехкомпонентной смеси ПАУ по спектрам в УФ-видимой области (искусственные данные).
 - общие навыки калибровки, интерпретации и диагностики модели, предсказания на «идеальных» данных
- Пример 2. Определение октанового числа топлива по спектрам ближнего ИК.
 - калибровка на реальных данных, обнаружение и удаление выбросов
- Пример 3. Качество пшеницы (факультативно).
 - самостоятельное построение калибровки, MSC, выбор переменных



Рекомендуемая литература

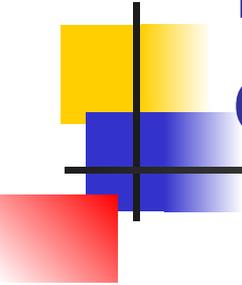
- Richard Kramer
Chemometric Techniques for Quantitative Analysis *
- Kim H. Esbensen
Multivariate Data Analysis - in Practice **
- Kenneth R. Beebee et al.
Chemometrics: a Practical Guide **
- Harald Martens, Tormod Naes
Multivariate Calibration **
- Richard G. Brereton
Chemometrics: Data Analysis for the Laboratory and Chemical Plant ***
- Edmund R. Malinowski
Factor Analysis in Chemistry ****



Пример 1: Калибровка смеси ПАУ

Цель: выработка навыков калибровки с программой Unscrambler

- изучить наборы данные: обучающий, тестовый, «unknown» - в таблице, как серии спектров
- построить калибровки: РГК, ПЛС2 - сравнить модели
- построить ПЛС1 для каждого из 3-х компонентов, определить размерность моделей
- изучить графики scores, loadings, T-U, Predicted vs Measured, RMSEP, Variance для [C1] - [C3] с разным количеством факторов
- предсказать «неизвестные» образцы

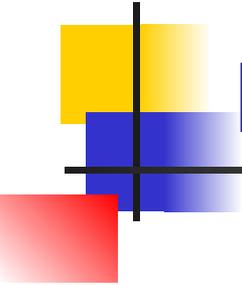


Пример 2: Определение октанового числа бензина

стр. 139, файл Octane

Цель: работа с реальными данными, диагностика и устранение выбросов

- преимущественно по книге:
- построить калибровку ПЛС1, диагностировать
- определить выбросы, удалить, обнести калибровку
- проверить модель различными способами, включая тестовый набор
- построить РГК, сравнить модели
- предсказать «неизвестные» образцы



Пример 3: Качество пшеницы

стр. 150, файл Wheat

Цель: самостоятельное построение калибровочной модели

- построение моделей ПЛС1/2, сравнение моделей
- определение и удаление выбросов
- применение MSC
- попробовать удаление переменных для улучшения модели