

Лаборатория адаптивных методов обработки данных (ЛАМОД)

ПРИМЕНЕНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ РЕШЕНИЯ МНОГОПАРАМЕТРИЧЕСКИХ ОБРАТНЫХ ЗАДАЧ

“...она поспела как раз вовремя, чтобы заметить, как Белый Кролик скрылся в большой норе под колючей изгородью.

В ту же секунду Алиса не раздумывая ринулась за ним. *А кой о чем подумать ей не мешало бы – ну хоть о том, как она выберется обратно!”*

Льюис Кэрролл. Алиса в стране чудес

Научный семинар «Глубокое обучение в вычислительной физике»

13 мая 2021 г.

Общая постановка обратной задачи:



Наблюдаемыми являются значения Y ; как правило, $m \gg n$

Задача: научиться восстанавливать значения X по значениям Y

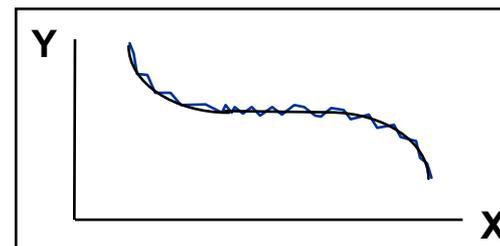
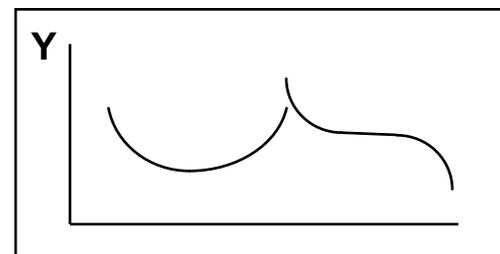
Такая задача представляет собой задачу моделирования **обратной** функции $X = F^{-1}(Y)$

Проблемы:

- единственность решения
- устойчивость решения

Неединственность и неустойчивость:

- теоретические
- практические



Обратная задача называется **корректной по Адамару**, если:

- 1) $\forall Y \exists !X: Y=F(X)$ (решение единственно)
 - 2) $\forall \delta \exists \varepsilon: (\Delta Y < \delta) \Leftrightarrow (\Delta X < \varepsilon)$ (решение устойчиво)
- во всей области определения X .

Причины практической некорректности:

- наличие шумов в экспериментальных данных (неустойчивость)
- дискретность набора экспериментальных точек (неединственность)

Jacques Hadamard
(1865 – 1963)



Обратная задача называется **корректной по Тихонову** (в случае нарушения корректности по Адамару), если в пространстве $\{X\}$ можно выделить более узкое множество решений $\{X'\}$ такое, что:

1) *a priori* известно, что $\exists X \in \{X'\}$

(решение существует)

2) $\forall Y \exists ! X \in \{X'\} : Y = F(X)$

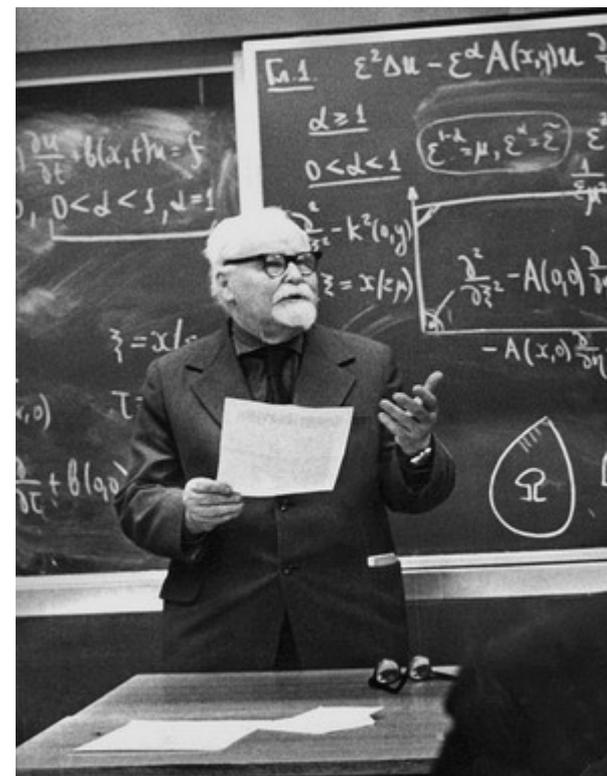
(решение единственно)

3) $\forall \delta \exists \varepsilon : (\Delta Y < \delta) \Leftrightarrow (\Delta X < \varepsilon)$,

если $(X + \Delta X) \in \{X'\}$

(решение устойчиво).

Акад. Тихонов Андрей Николаевич
(1906 – 1993)



Задача называется **хорошо обусловленной**, если малым погрешностям исходных данных соответствуют малые погрешности решения

Задача называется **плохо обусловленной**, если малым погрешностям исходных данных соответствуют большие погрешности решения

Абсолютное число обусловленности μ_{Δ} : $\Delta y \leq \mu_{\Delta} \cdot \Delta x$

Относительное число обусловленности: μ_{δ} : $\delta y \leq \mu_{\delta} \cdot \delta x$

Δ – абсолютное изменение, δ – относительное изменение

Чем меньше число обусловленности, тем лучше

Корректная задача может быть плохо обусловленной!

Некорректная задача имеет число обусловленности, равное ∞

ПОСТАНОВКА ОБРАТНЫХ ЗАДАЧ С ТОЧКИ ЗРЕНИЯ МЕТОДОВ ОБРАБОТКИ ДАННЫХ



Одну и ту же обратную задачу (ОЗ) можно поставить несколькими разными способами :

1) Как задачу *оценки*

(оценка значений обратной функции $X = F^{-1}(Y)$)

Используются методы восстановления зависимостей, в том числе и методы машинного обучения (ММО)

2) Как задачу *оптимизации*

(подбор оптимальных параметров прямой функции $Y = F(X)$)

Используются методы (многомерной) оптимизации

3) Как задачу *классификации*

(если вектор параметров X принимает дискретные значения)

Используются методы решения задач классификации (распознавания образов)

1. Подход "от эксперимента"

Задан экспериментальный массив данных для обучения

$$S_k = (X, Y)_k, k = 1 \dots N$$

Значения искомых параметров известны *a priori*

или определены экспериментально альтернативными методами

- а) Разделение массива на тренировочный, валидационный и тестовый наборы
- б) Обучение метода оценке значений обратной функции $X(Y)$

2. Подход "от модели"

Требует наличия аналитической или вычислительной модели прямой функции $Y = F(X)$

- а) Задание диапазона изменения X и "сетки" значений
- б) Генерация необходимого количества данных с необходимой представительностью для всех наборов посредством решения прямой задачи
- в) Обучение метода оценке значений обратной функции $X(Y)$

3. Промежуточный “квазимодельный” подход

Используется интерполяционная или экстраполяционная генеративная модель, основанная на “опорных” векторах наблюдаемых значений, получаемых экспериментально

Области применения методических подходов

Имеется ли адекватная аналитическая/численная модель объекта?	Да	Нет	Нет
Имеется ли достаточное количество экспериментальных данных?		Да	Нет
Рекомендуемый методический подход	“от модели”	“от эксперимента”	“квази-модельный”

МЕТОДИЧЕСКИЕ ПОДХОДЫ К РЕШЕНИЮ ОБРАТНЫХ ЗАДАЧ С ПОМОЩЬЮ ММО



Сравнение свойств методических подходов

Характеристика	"От эксперимента"	"Квазимодельный"	"От модели"
Представительность наборов данных	Как правило, недостаточная	Адекватная	Адекватная
Наличие шумов в данных	Присутствуют всегда	Присутствуют всегда	Могут быть введены искусственно
Уровень шумов в данных	Определяется экспериментом	Определяется экспериментом	Задается при моделировании
Проведение экспериментов	Необходимо, масштабное	Необходимо, ограниченное	Желательно для проверки
Наличие модели решения ПЗ	Не требуется	Требуется "квазимодель"	Требуется
Адекватность решения объекту	Высокая	В меру адекватности "квазимодели"	В меру адекватности модели

- Обучение **на примерах**
- Устойчивость к **противоречивым** данным
- Устойчивость к **шумам**
- Устойчивость к умеренному изменению **побочных параметров** объекта,
не являющихся искомыми
в процессе решения обратной задачи

- Основаны на **аппроксимации** обратной функции
- Не требуют **априорного знания** о характере искомой зависимости (наличия точной модели)
- Требуют наличия **представительного** набора данных
- Обладают высокой практической **устойчивостью**
- Основываются в своей оценке на информации, получаемой из **всей** обучающей выборки
- Используют в качестве целевой функции в оптимизационной процедуре **расстояние** непосредственно **в пространстве искомых параметров**, а не в пространстве наблюдаемых величин (минимумы невязки в разных пространствах не соответствуют друг другу!)
- Проблема наличия **ошибок**

Аппроксимационные методы (ММО) следует применять,

когда:

- Обратная задача не может быть решена **аналитически или численно**
- Данные **противоречивы** или характеризуются значительным уровнем **шума**
- Аналитическая или вычислительная модель решения **прямой задачи** отсутствует или неустойчива
- **Априорная информация** об объекте отсутствует, или её использование затруднено

Некоторые аппроксимационные методы машинного обучения, эффективные при решении обратных задач:

- Искусственные **нейронные сети** (далеко не всегда глубокие!)
ИНС – универсальный аппроксиматор!
- Градиентный **бустинг**
- Алгоритм **случайного леса**
- **Линейная регрессия** в нелинейном базисе
- Метод частичных наименьших квадратов
(метод **проекций на латентные структуры**, ПЛС)
- Метод **группового учёта аргументов** (МГУА)

Высокая размерность входных данных сильно снижает эффективность применения аппроксимационных методов.

Основные **способы понижения входной размерности**:

- **Отбор** существенных входных признаков, напр., с помощью:
 - Кросс-корреляционного и кросс-энтропийного анализа
 - Оценки дисперсии значений входного признака
 - Анализа весов нейронной сети
- **Преобразование** входного признакового пространства, напр.:
 - Анализ главных компонент, линейный и нелинейный
 - Агрегация признаков
 - Вейвлет-анализ

- **Одновременное** определение (1 модель, N выходов)
- **Автономное** определение (N моделей с 1 выходом каждая)
- **Групповое** определение (объединение параметров в группы с одновременным определением внутри каждой группы)
- **Поэтапное** определение (на начальных этапах определяются те параметры, для которых задача решается хорошо; на последующих этапах их полученные значения подаются на вход вместе со значениями входных признаков).

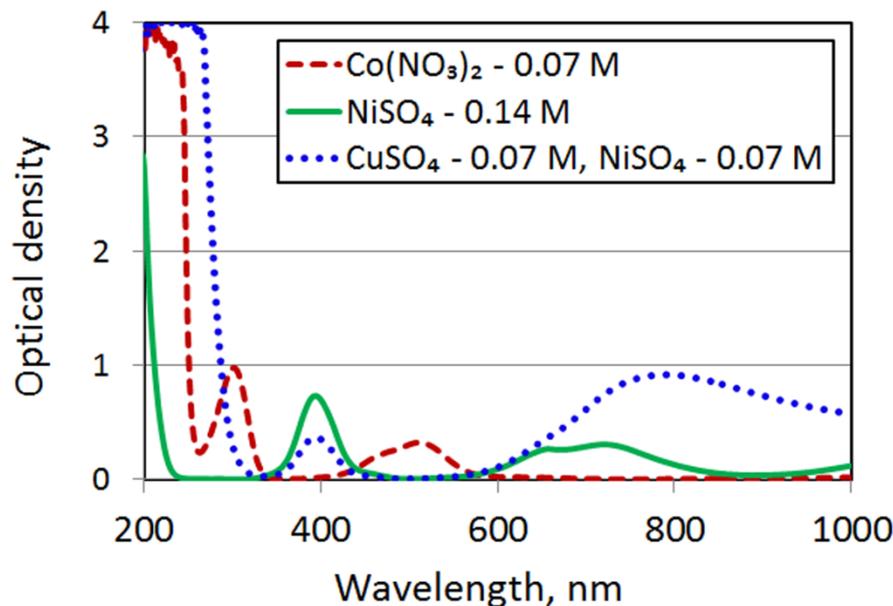
Наиболее эффективным является **групповое** определение при наличии возможности правильного объединения параметров.

- Эффективный приём: **добавление шума** к обучающим примерам в процессе обучения модели
 - Параметры **добавляемого** шума должны соответствовать аналогичным параметрам шума в **тестовом** наборе:
 - **Природа** шума (способ влияния на данные – напр. аддитивный, мультипликативный, «корневой»)
 - **Статистика** шума (распределение реализаций в пределах амплитуды (напр. равномерный, гауссов)
 - **Амплитуда** шума (максимальная или характерная величина)
-

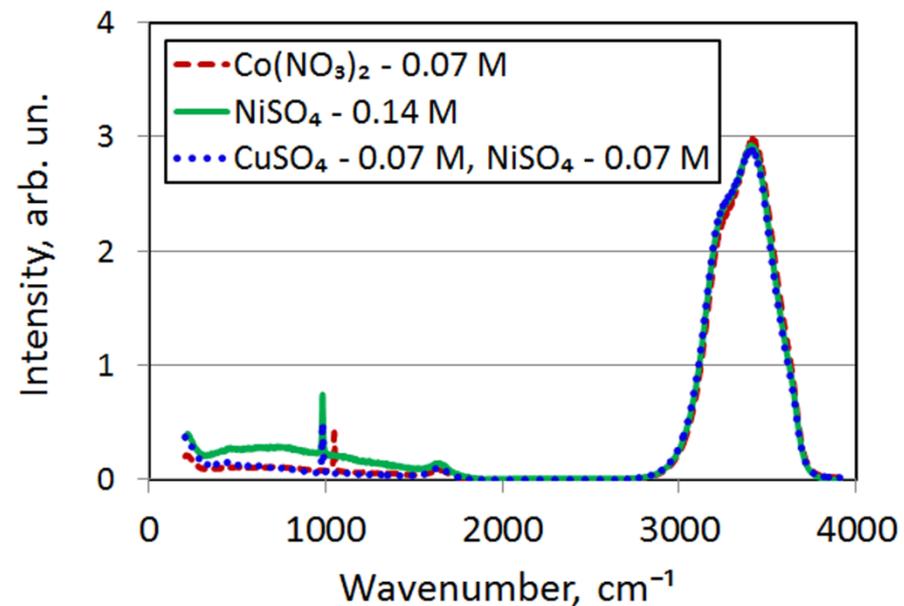
- Комплексирование **аппроксиматоров** (комитеты / ансамбли)
 - Основано на **нескоррелированности** ошибок
 - Максимальное **разнообразие** предикторов
 - **Раздельные или совместные** отбор или преобразование признаков
- Комплексирование **данных** (бэггинг)
 - **Независимость** всех поднаборов
 - Сохранение **представительности** всех поднаборов
- Комплексирование **физических методов**
 - Согласованное решение нескольких **различных** ОЗ с одними и теми же определяемыми параметрами
 - **Раздельное или совместное** решение ОЗ
 - **Раздельные или совместные** отбор или преобразование признаков

Пример 1: Обратные задачи спектроскопии

- **Объект исследования:** многокомпонентные водные растворы неорганических солей тяжёлых металлов CuSO_4 , NiSO_4 , CoSO_4 , $\text{Cu}(\text{NO}_3)_2$, $\text{Ni}(\text{NO}_3)_2$, $\text{Co}(\text{NO}_3)_2$
- В каждом растворе от 0 до 6 солей, от 0 до 5 ионов
- Для каждого раствора измерялось также pH
- Спектры поглощения и спектры комбинационного рассеяния



Поглощение

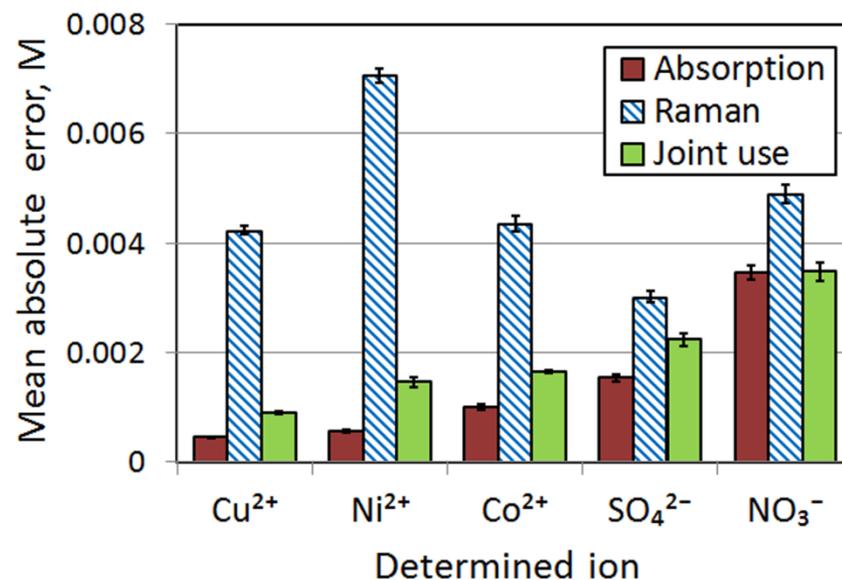
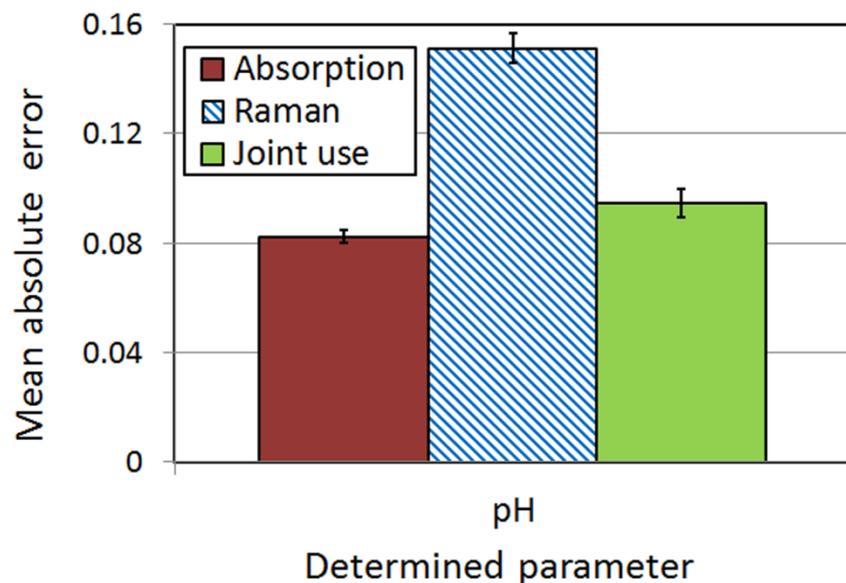


Комбинационное рассеяние

Пример 1: Методика работы с данными

- **3806 примеров** (растворов) = 2656 трн + 750 влд + 400 тст
- **2048 каналов** в спектре комбинационного рассеяния (КР)
- **811 каналов** в спектре поглощения
- Входные признаки: только поглощение, только КР, оба
- **pH** использовался как входной либо как выходной признак
- Автономное определение
(отдельная сеть для каждого определяемого параметра)
- Многослойный персептрон с 1...3 скрытыми слоями («мелкий»)
- Однородный комитет из 5 идентичных сетей с разной инициализацией весов
- Исходный набор, отбор, преобразование признаков

Пример 1: Базовый эксперимент

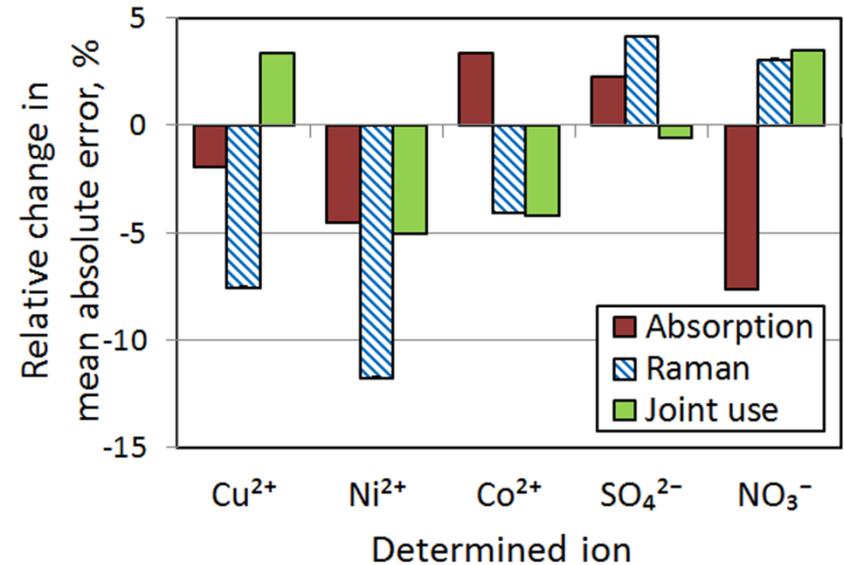
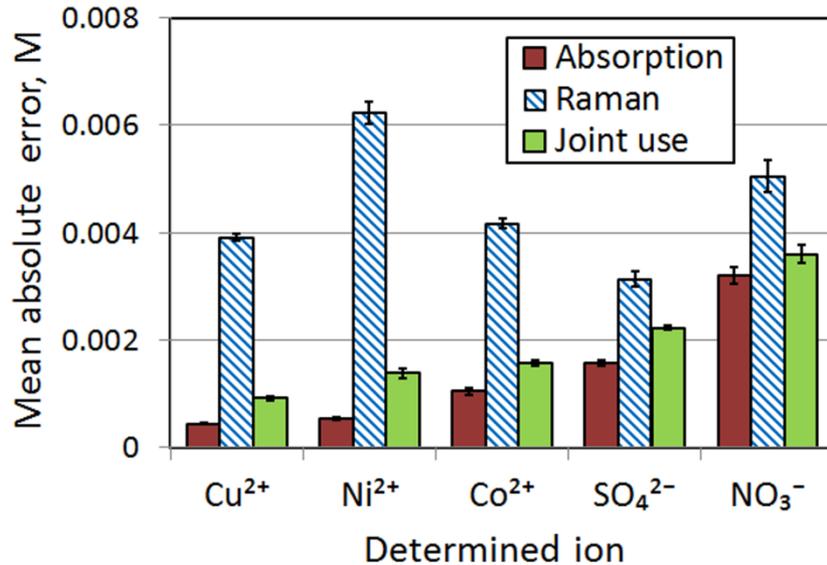


Базовый эксперимент (полные наборы входных признаков)

При совместном использовании на вход подавались

оба массива входных признаков **параллельно**

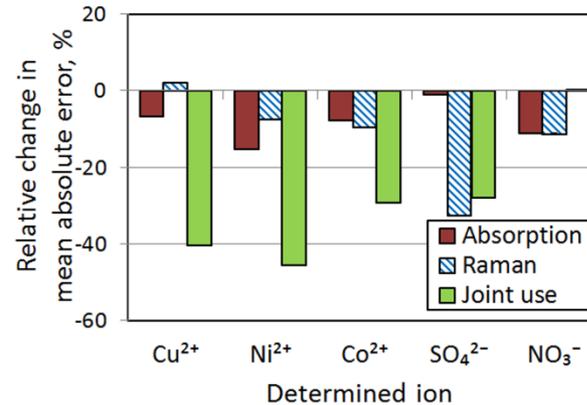
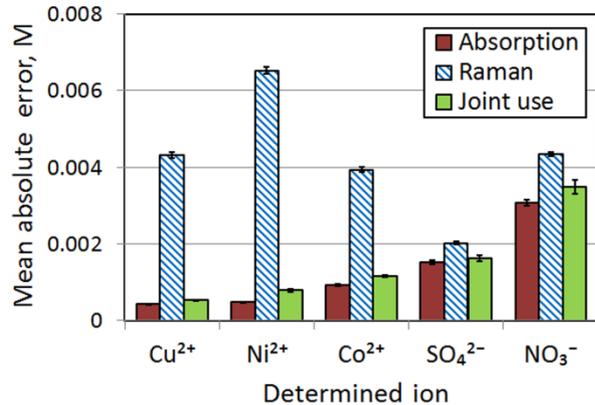
Пример 1: Использование рН



Результаты включения рН в число входных признаков

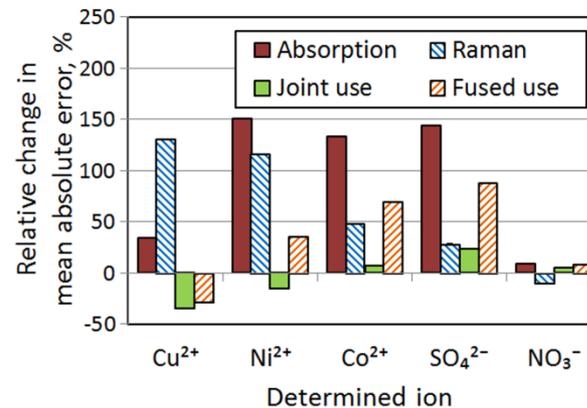
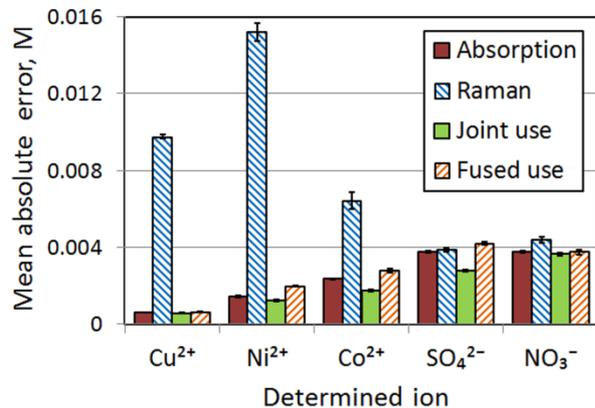
Справа – относительное изменение в %
средней абсолютной ошибки

Пример 1: Отбор и преобразование признаков



Отбор признаков (анализ весов нейронной сети)

100 признаков для поглощения, 250 признаков для КР, 350 для обоих



Преобразование признаков (анализ главных компонент)

99% описанной дисперсии. 6 признаков для поглощения, 5 признаков для КР, 11 для обоих, 7 для совместного

Пример 2: Обратные задачи геологоразведки

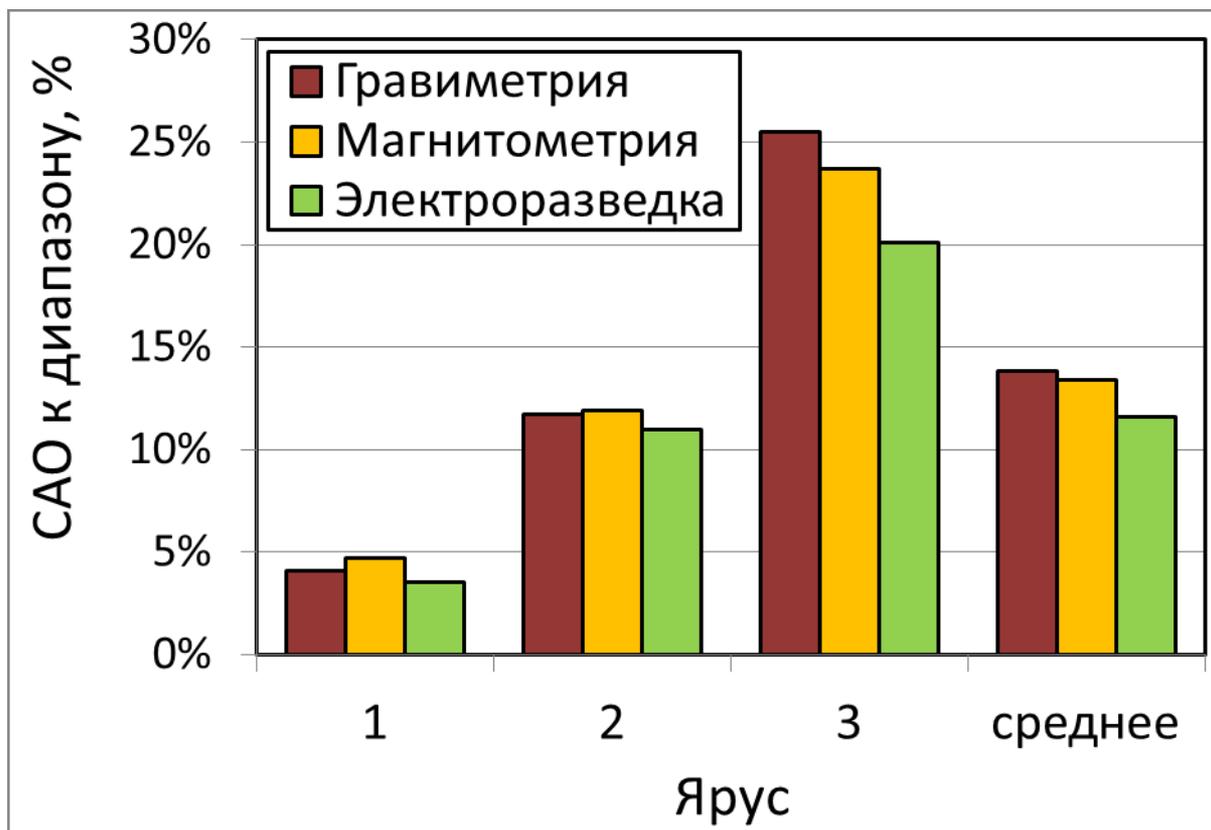
- **Объект исследования:** определение структурных границ, разделяющих геологические слои с постоянными значениями параметра:
 - Плотности в задаче гравиметрии
 - Намагниченности в магнитометрии
 - Удельного сопротивления в электроразведке
- Измеряются гравитационное, магнитное, электромагнитное поля
- 4-слойная синтезированная 2D модель
- Протяженность профиля 15 км
- Шаг измерения 0.5 км – итого 31 точка измерений по профилю
- Определяются 45 параметров

Пример 2: Методика работы с данными

- **10000 примеров** в каждой БД = 7000 трн + 2000 влд + 1000 тст
- **31** входной признак для гравиметрии и магнитометрии
- **62** входных признака для электроразведки
- **45** выходных признаков (мощности слоёв)
- Автономное определение
(отдельная сеть для каждого определяемого параметра)
- Многослойный персептрон с 3 скрытыми слоями («мелкий»)
- Исходный набор признаков
- Комплексование методов со слиянием признаков
- Мера ошибки – средняя абсолютная ошибка к диапазону D_s

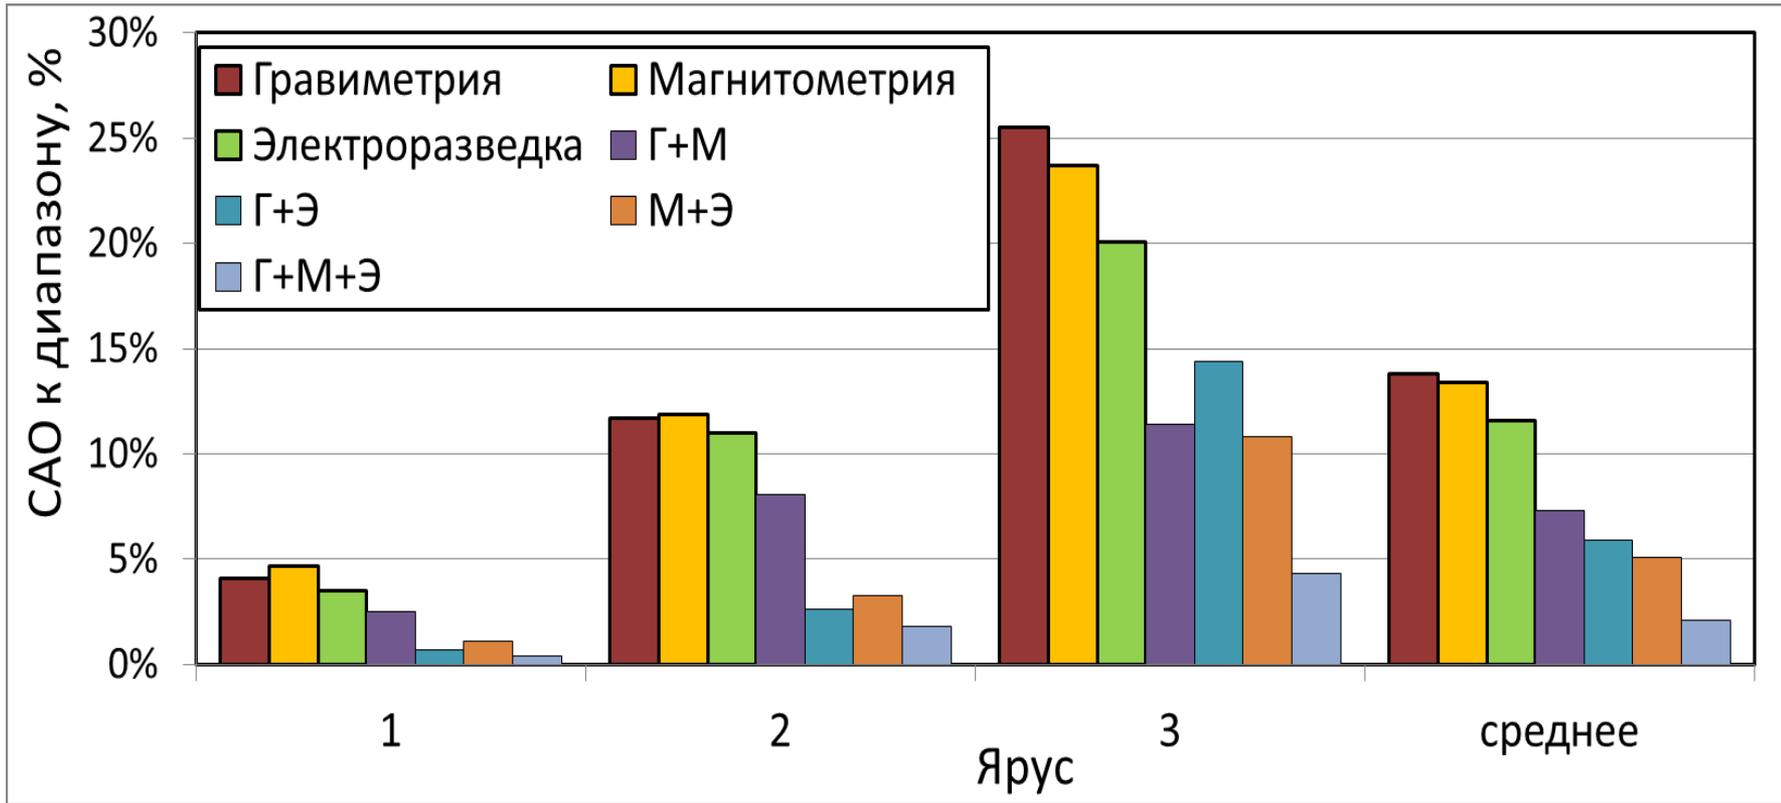
$$\|s - s'\|_{l_1}^N = \sum_{n=1}^N \frac{1}{D_s} \frac{1}{N} |s_n - s'_n| = \frac{1}{D_s N} \sum_{n=1}^N |s_n - s'_n|$$

Пример 2: Базовый эксперимент



Базовый эксперимент (полные наборы входных признаков)

Пример 2: Комплексирование



Результаты комплексирования физических методов

Выводы по комплексированию

- Если физические методы **сильно отличаются** по уровню ошибки, комплексирование **не работает**
- Если физические методы дают **близкий уровень** ошибки, комплексирование **работает**
- Дальнейшие направления работ
 - Использование на обеих задачах комплексирования аппроксиматоров
 - Использование на обеих задачах комплексирования данных

ПРИМЕНЕНИЕ МЕТОДОВ МАШИННОГО ОБУЧЕНИЯ ДЛЯ РЕШЕНИЯ МНОГОПАРАМЕТРИЧЕСКИХ ОЗ: **ИТОГИ**



Рассмотрены различные методические подходы к решению ОЗ:

- От модели
- От эксперимента
- Квазимодельный

Продемонстрирована эффективность следующих методик:

- Понижение размерности входных данных
- Способы определения выходных параметров
 - Одновременное
 - Автономное
 - Групповое
 - Поэтапное
- Тренировка на данных с добавлением шума
- Комплексование
 - Аппроксиматоров
 - Данных
 - Физических методов

Лаборатория адаптивных методов обработки данных (ЛАМОД)

СПАСИБО ЗА ВНИМАНИЕ!

“- Просыпайся, дорогая, - сказала сестра. Что-то ты очень разоспалась!
- Ой, а какой я забавный сон видела! – сказала Алиса. “

Льюис Кэрролл. Алиса в стране чудес

Научный семинар «Глубокое обучение в вычислительной физике»

13 мая 2021 г.