

# Большие данные



д.т.н., профессор  
**Холод Иван Иванович**  
[iiholod@mail.ru](mailto:iiholod@mail.ru)

Введение в курс.

# Цель и задачи курса

**Цель:** формирование представления о развитии средств и методов обработки и анализа Больших данных.

## **Задачи:**

- изучение знаний по базовым методам и алгоритмам обработки и анализа Больших данных и их усовершенствования для выполнения в параллельной и распределенной среде;
- формирование умений и практических навыков разработки алгоритмического и программного обеспечения методов анализа Больших данных;
- освоение навыков применения методов и алгоритмов анализа Больших данных;



# Структура курса

1. введение в курс;
2. поколения платформ данных;
3. хранение Больших данных;
4. обработка потоковых данных ;
5. распределенная обработка данных;
6. алгоритмы анализа Больших данных;
7. федеративное обучение;
8. алгоритмы федеративного обучения;



# Анализ Больших данных. On-line

- **Модуль 1. Введение в анализ Больших данных** (Тест 20 вопросов):
  - Блок 1. Большие данные
  - Блок 2. Методы анализа данных
  - Блок 3. Поколения платформ Больших данных
  - Блок 4. Анализ распределенных данных
- **Модуль 2. Хранение Больших данных** (Тест 20 вопросов):
  - Блок 1. Реляционные (SQL) БД
  - Блок 2. noSQL БД
  - Блок 3. newSQL БД
  - Блок 4. Распределенные хранилища данных
- **Модуль 3. Распределенный анализ Больших данных** (тест 20 вопросов)
  - Блок 1. Масштабирование вычислений для Больших данных
  - Блок 2. Параллельное обучение
  - Блок 3. Распределенные вычисления
  - Блок 4. Парадигма Map Reduce
  - Блок 5. Системы распределенного анализа данных
- **Модуль 4. Обработка потоковых данных** (Тест 20 вопросов)
  - Блок 1. Проблемы потоковой обработки
  - Блок 2. Требования к потоковой обработке
  - Блок 3. Архитектура
- **Модуль 5. Федеративное обучение** (Тест 20 вопросов)
  - Блок 1. Новая концепция анализа распределенных данных
  - Блок 2. Распределение данных
  - Блок 3. Классы систем федеративного обучения
  - Блок 4.1 Безопасность федеративного обучения. Виды атак.
  - Блок 4.2 Безопасность федеративного обучения. Методы защиты
  - Блок 5. Библиотеки федеративного обучения
  - Блок 6. Применение федеративного обучения



# Структура курса

	н1	н2	н3	н4	н5	н6	н7	н8	н9	н10	н11	н12	н13	н14	н15	н16	н17
Модули	0	1	-	2	2	2	3	3	3	3	4	4	5	5	5	5	5
Доклады					1	1		2	2	3		4		5	5	6	6
Практика	к	к	к	1	1	1	к	к	2	2	2	к	к	3	3	3	3

Практические занятия:

- теоретическая часть

- on-line лекции (LETITech)

- доклады на парах

1. системы хранения Больших данных

2. системы распределенной обработки Больших данных

3. **алгоритмы распределенных данных**

4. системы обработки потоковых данных

5. фреймворки Федеративного обучения

6. **алгоритмы федеративного обучения**

- практическая часть

- теоретическое проектирование

- практическая реализация.



# Практика. Треки

## 1. Основной трек: Анализ Больших данных. Apache Spark в Yandex.Cloud. DataSphere

Выбор: набора данных, задачи анализа, алгоритма из Apache Spark MLlib

Последовательный анализ набора данных

Параллельный анализ набора данных (2, 8, 32 процессора)

## 2. Альтернативный трек: Федеративное обучение

2.1. Анализ с использованием Python FL framework (TFF, FATE, PySyft, Flower, FedML)

- простой набор данных – [пр.практика \(ЛЭТИ\)](#)

2.2. Анализ с использованием FL4J – [пр.практика \(ЛЭТИ\)](#)

2.3. Разработка алгоритмов FL для FL4J – [пр.практика \(ЛЭТИ\)](#)

2.4. Доработка фреймворка FL4J – [пр.практика \(ЛЭТИ\)](#)

2.5. Доработка GUI (Vue.js) для FL4J – [пр.практика \(ЛЭТИ\)](#)



# Основной трек. Анализ данных

Реализация аналитической задачи методом машинного обучения на данных большого объема алгоритмом из модуля Apache Spark MLlib в Yandex.Cloud и Data Shpere

## Группы по 2 человека:

- инженер данных;
- ML аналитик;

## На выбор:

- набор данных;
- решаемая задача
- используемые ML алгоритм из модуля Apache Spark MLlib;

## Порядок выполнения:

- 1.Теоретическое проектирование: **Доклад №1**
- 2.Практическая реализация: Доклад №2 по результатам
  1. Последовательное выполнение ML алгоритма
  2. Параллельное выполнение ML алгоритма



# Альтернативный трек. Фед. обучение

Реализация аналитической задачи методом федеративного обучения на данных большого объема в Yandex.Cloud с использованием VM

Группы по 2 человека:

- инженер;
- FL аналитик;

**На выбор:**

- набор данных (три набора данных);
- фреймворк;
- FL алгоритм;

**Порядок выполнения:**

1. Теоретическое проектирование: **Доклад №1**
2. Практическая реализация: Доклад №2 по результатам
  1. выполнение FL алгоритма на одном узле
  2. выполнение FL алгоритма на нескольких узлах



# План доклада №1

## Подходы к анализу данных

1. Общая информация по данным: источник, кем предоставлены, когда и для каких задач могут использоваться.
2. Описание целевой задачи анализа данных исходя из данных
3. Метаинформация: формат, количество атрибутов и векторов, типы атрибутов, классы и т.п.
4. Ограничения данных: пропущенные значения, аномалии, и т.п..
5. Предлагаемый ML алгоритм (**из модуля Apache Spark MLlib**) для решения целевой задачи
6. Необходимые настройки данных для каждого алгоритма.
7. Ожидаемые модели знаний, построенные алгоритмами.
8. Предлагаемые методы и критерии оценки построенных моделей.



# План доклада №2

## Результаты анализа данных

1. Процесс анализа: выполненные этапы анализа и итерации;
2. Настройки/преобразования данных (привести фрагменты физических и логических данных).
3. Настройки функций (привести скриншот).
4. Настройки алгоритма (привести скриншоты).
5. Построение моделей алгоритмом: время построения в зависимости от объема данных;
6. Построение модели : время построения в зависимости от числа вычислителей;
7. Построенные модели и их оценки.
8. Выводы.



# Структура пояснительной записки

1. Общая информация по данным: источник, кем предоставлены, когда и для каких задач могут использоваться.
2. Описание целевой задачи анализа данных
3. Метаинформация: формат, количество атрибутов и векторов, типы атрибутов, классы и т.п.
4. Ограничения данных: пропущенные значения, аномалии, и т.п..
5. Предлагаемые алгоритмы Data Mining для решения целевой задачи (не менее 3х алгоритмов)
6. Необходимые настройки данных для каждого алгоритма.
7. Ожидаемые модели знаний, построенные алгоритмами.
8. Предлагаемые методы и критерии оценки построенных моделей.
9. Выбранная среда для анализа: разработчик, лицензия, версия, и т.п.
10. Процесс анализа: выполненные этапы анализа и итерации;
11. Настройки/преобразования данных (привести фрагменты физических и логических данных).
12. Настройки функций (привести скриншот).
13. Настройки каждого алгоритма (привести скриншоты).
14. Построение моделей каждым алгоритмом: время построения в зависимости от числа данных;
15. Построенные модели (каждым алгоритмом) и их оценки.
16. Выводы.



# Оценка знаний

Оценка по дисциплине формируется из:

1. оценки за теоретическую часть (**минимум 10**, максимум >40 баллов);
2. оценки за практическую часть (**минимум 20**, максимум 40 баллов).

Допуск к экзамену если выполнены два условия:

1. выполнена практическая часть  $\geq 20$ ;
2. пройдены тесты в on-line курсе  $\geq 10$  (правильные ответы минимум 50%).

Итоговая оценка вычисляется следующим образом:

1. 5 если набрано баллов  $\geq 80$  баллов;
2. 4 если  $60 < \text{набрано баллов} < 80$ ;
3. 3 если  $40 < \text{набрано баллов} \leq 60$ ;
4. не аттестован если  $\leq 40$  баллов



# Оценка знаний. Теоретическая часть

Оценка за теоретическую часть может быть получена:

1. тесты в on-line курсе – **минимум 10**, максимум 20 баллов (*1 балл за 5 ответов*)
2. за ответы на вопросы на лекциях;
3. за доклад - максимум 10 баллов;
4. за оппонирование докладов - максимум 5 баллов
5. за экзамен - максимум 10 баллов за вопрос.



# Оценка знаний. Практическая часть

Оценка за **практическую часть** может быть получена за доклады и выполнение заданий:

- доклад 1 – максимум 10 баллов
- доклад 2 – максимум 20 баллов:
  - последовательный алгоритм (10 баллов)
  - масштабированный алгоритм (10 баллов)

Презентации присылаются на проверку **за 1 неделю** до доклада.

График сдачи работы:

Доклад	Срок	Штраф
Теоретическое проектирование	20.03.2023	3 балла до 20.04, 6 после
Последовательное выполнение алгоритма	24.04.2023	3 балла до 22.05, 6 после
Параллельное выполнение алгоритма	19.05.2023	5 баллов после 20.05

10 дополнительных баллов за выполнения ВСЕЙ практики до 01.05



# Вопросы?

