

Аннотация дисциплины Б.1.1.27 Дисциплина. Основы работы с большими данными

Дисциплина "Основы работы с большими данными" изучается обучающимися по основной профессиональной образовательной программе "Прикладная статистика и анализ данных" направления подготовки "01.03.05 Статистика".

Дисциплина изучается в 5 семестре. Общая трудоемкость дисциплины составляет 180/5 часов/з.ед. Самостоятельная работа заключается в выполнении работ, указанных в разделе 4.

В ходе изучения дисциплины осуществляется текущий контроль в форме технологии рейтингового контроля в соответствии с технологической карты дисциплины, размещенной на электронном курсе, а также промежуточный контроль в форме экзамен.

Целью изучения дисциплины является формирование следующих компетенций:

1. ОПК-1 Способен осуществлять статистическое наблюдение с использованием стандартных методик и технических средств, включая формирование выборочной совокупности и подготовку статистического инструментария
2. ОПК-2 Способен формировать упорядоченные сводные массивы статистической информации и осуществлять расчет сводных и производных показателей в соответствии с утвержденными методиками, в том числе с применением необходимой вычислительной техники и стандартных компьютерных программ

В ходе изучения дисциплины последовательно рассматриваются темы:

1. Предмет курса. Основные понятия, области применения и примеры использования Больших Данных. Архитектура хранилищ Больших Данных. Распределенные базы данных (БД). CAP-теорема и ее следствия для бизнеса. Введение в экосистему Hadoop.
2. Модели данных. NoSQL, базы данных. Операции CRUD в реляционных и NoSQL БД. Технология MapReduce для работы с BigData. Программные продукты для анализа Больших Данных. Аналитическая платформа Loginom. Язык Python как инструмент анализа данных.
3. Структурированные и неструктурированные данные. Подготовка данных к анализу. Алгоритмы выборки, очистки, сортировки;
4. Поиск закономерностей в данных. Визуализация данных. Статистический анализ данных. Кластерный анализ. Модели временных рядов.
5. Основы языка Python. Библиотеки для анализа данных (NumPy, Matplotlib, scikit-learn)
6. Смешение и интеграция данных - набор техник интегрировать разнородных данных. Имитационное моделирование – построение моделей имитирующих реальные процессы, разновидность экспериментальных испытаний. Пространственный анализ - класс методов, использующих топологическую, геометрическую и географическую информацию в данных.
7. Алгоритмы машинного обучения для решения задач регрессии, классификации и кластеризации. Алгоритмы работы рекомендательных систем и прогнозирования. Методы бустинга в задачах распознавания и видеоаналитики. Нейронные сети в задачах классификации. Задача классификации изображений. Оценка качества классификации.
8. Алгоритмы Data mining — глубинный анализ данных. Классификация. Ассоциация. Регрессионный анализ.

Основными стратегическими образовательными технологиями являются: лекционные занятия, практические и лабораторные занятия, процедуры самообучения.

В рамках указанных технологий применяются тактические образовательные технологии: задания, классическая лекция.