

МИНИСТЕРСТВО ТРАНСПОРТА РОССИЙСКОЙ ФЕДЕРАЦИИ
ФЕДЕРАЛЬНОЕ ГОСУДАРСТВЕННОЕ АВТОНОМНОЕ ОБРАЗОВАТЕЛЬНОЕ
УЧРЕЖДЕНИЕ ВЫСШЕГО ОБРАЗОВАНИЯ
«РОССИЙСКИЙ УНИВЕРСИТЕТ ТРАНСПОРТА»
(РУТ (МИИТ))



Рабочая программа дисциплины (модуля),
как компонент образовательной программы
высшего образования - программы бакалавриата
по направлению подготовки
09.03.01 Информатика и вычислительная техника,
утвержденной первым проректором РУТ (МИИТ)
Тимониным В.С.

РАБОЧАЯ ПРОГРАММА ДИСЦИПЛИНЫ (МОДУЛЯ)

Методы анализа и обработки больших данных

Направление подготовки: 09.03.01 Информатика и вычислительная техника

Направленность (профиль): IT-сервисы и технологии обработки данных на транспорте

Форма обучения: Очная

Рабочая программа дисциплины (модуля) в виде электронного документа выгружена из единой корпоративной информационной системы управления университетом и соответствует оригиналу

Простая электронная подпись, выданная РУТ (МИИТ)
ID подписи: 170737
Подписал: заместитель директора академии Паринов Денис Владимирович
Дата: 13.06.2024

1. Общие сведения о дисциплине (модуле).

Целью освоение дисциплины (модуля) является приобретения практически навыков и умений, позволяющих создавать высокопроизводительные реализации известных методов вычислительной математики, анализа и обработки больших данных.

Задачами освоения дисциплины (модуля) являются:

освоение базовых знаний в области архитектуры современных многопроцессорных вычислительных систем параллельной обработки информации,

освоений технологий организации параллельных вычислений на многопроцессорных вычислительных комплексах с распределенной или общей оперативной памятью.

2. Планируемые результаты обучения по дисциплине (модулю).

Перечень формируемых результатов освоения образовательной программы (компетенций) в результате обучения по дисциплине (модулю):

ОПК-3 - Способен решать стандартные задачи профессиональной деятельности на основе информационной и библиографической культуры с применением информационно-коммуникационных технологий и с учетом основных требований информационной безопасности;

ОПК-4 - Способен участвовать в разработке стандартов, норм и правил, а также технической документации, связанной с профессиональной деятельностью;

ОПК-9 - Способен осваивать методики использования программных средств для решения практических задач;

ПК-1 - Способен анализировать большие данные с использованием существующей в организации методологической и технологической инфраструктуры.

Обучение по дисциплине (модулю) предполагает, что по его результатам обучающийся будет:

Знать:

программное обеспечение, необходимое для работы с большими данными,

необходимые элементы инфраструктуры для обработки больших данных.

Уметь:

Обрабатывать данные в Hadoop
Работать с распределенными файловыми системами в Hadoop
Настраивать кластеры в Hadoop
Составлять спецификации оборудования для различных задач

Владеть:

Инструментами настройки сетей
Знаниями о высокопроизводительных вычислениях
Навыками работы со статистическими параметрами вычислений
Технологиями параллельной обработки данных
Навыками работы с vCenter Server
Инструментами работы с Hadoop
Техниками настройки кластеров в Hadoop

3. Объем дисциплины (модуля).

3.1. Общая трудоемкость дисциплины (модуля).

Общая трудоемкость дисциплины (модуля) составляет 4 з.е. (144 академических часа(ов)).

3.2. Объем дисциплины (модуля) в форме контактной работы обучающихся с педагогическими работниками и (или) лицами, привлекаемыми к реализации образовательной программы на иных условиях, при проведении учебных занятий:

Тип учебных занятий	Количество часов	
	Всего	Семестр №5
Контактная работа при проведении учебных занятий (всего):	80	80
В том числе:		
Занятия лекционного типа	32	32
Занятия семинарского типа	48	48

3.3. Объем дисциплины (модуля) в форме самостоятельной работы обучающихся, а также в форме контактной работы обучающихся с педагогическими работниками и (или) лицами, привлекаемыми к реализации образовательной программы на иных условиях, при проведении промежуточной аттестации составляет 64 академических часа (ов).

3.4. При обучении по индивидуальному учебному плану, в том числе при ускоренном обучении, объем дисциплины (модуля) может быть реализован полностью в форме самостоятельной работы обучающихся, а также в форме контактной работы обучающихся с педагогическими работниками и (или)

лицами, привлекаемыми к реализации образовательной программы на иных условиях, при проведении промежуточной аттестации.

4. Содержание дисциплины (модуля).

4.1. Занятия лекционного типа.

№ п/п	Тематика лекционных занятий / краткое содержание
1	Тема 1. Большие данные. История развития методов анализа и обработки Рассматриваемые вопросы: - эволюция понятия больших данных - хранилища данных - история развития методов обработки больших данных - отличия методов анализа от методов обработки больших данных
2	Тема 2. Жизненный цикл данных и метаданные Рассматриваемые вопросы: - элементы жизненного цикла и методы управления жизненным циклом - метаданные
3	Тема 3. Архитектура систем обработки больших данных Рассматриваемые вопросы: - прием данных - сбор данных - анализ данных - представления результатов - витрины данных
4	Тема 4. Введение в понятия высокопроизводительных вычислений. Рассматриваемые вопросы: - Важность проблематики параллельных вычислений - Пути достижения параллелизма. Векторная и конвейерная обработка данных. - Многопроцессорная и многомашинная, параллельная обработка данных. - Закон Мура, сдерживающие факторы наращивания количества транзисторов на кристалле и частоты процессоров. Привлекательность подхода параллельной обработки данных
5	Тема 5. Основные направления развития высокопроизводительных компьютеров. Рассматриваемые вопросы: - Сдерживающие факторы повсеместного внедрения параллельных вычислений - Ведомственные, национальные и другие программы, направленные на развитие параллельных вычислений в России. - Необходимость изучения дисциплины параллельного программирования. Перечень критических задач, решение которых без использования параллельных вычислений затруднено или вовсе невозможно.
6	Тема 6. Задачи параллельной обработки данных Рассматриваемые вопросы: - программные структуры алгоритмов параллельной обработки данных - инструменты параллельной обработки данных - конвейерно-параллельной обработки интегрированных потоков данных
7	Тема 7. Классификация вычислительных сетей Рассматриваемые вопросы:

№ п/п	Тематика лекционных занятий / краткое содержание
	<p>-Системы с распределенной, общей памятью, примеры систем.</p> <p>-Массивно-параллельные системы (MPP). Симметричные мультипроцессорные системы (SMP). - Параллельные векторные системы (PVP).</p> <p>-Системы с неоднородным доступом к памяти (Numa)</p> <p>-Компьютерные кластеры – специализированные и полнофункциональные. История возникновения компьютерных кластеров–проект Beowulf. Метакомпьютинг. Классификация Флинна, Шора и т.д. Организация межпроцессорных связей – коммуникационные топологии.</p> <p>-Примеры сетевых решений для создания кластерных систем</p>
8	<p>Тема 8. Основные принципы организации параллельной обработки данных: модели, методы и технологии параллельного программирования</p> <p>Рассматриваемые вопросы:</p> <p>-Функциональный параллелизм, параллелизм по данным.</p> <p>-Парадигма master-slave. Парадигма SPMD. Парадигма конвейеризации. Парадигма «разделяй и властвуй». Спекулятивный параллелизм. Важность выбора технологии для реализации алгоритма</p> <p>-Модель обмена сообщениями – MPI.</p> <p>-Модель общей памяти – OpenMP. Концепция виртуальной, разделяемой памяти – Linda.</p> <p>Российские разработки – Т-система, система DVM. Проблемы создания средства автоматического распараллеливания программ</p>
9	<p>Тема 9. Параллельное программирование с использованием интерфейса передачи сообщений MPI</p> <p>Рассматриваемые вопросы:</p> <p>-Библиотека MPI.</p> <p>- Модель SIMD. Инициализация и завершение MPI-приложения.</p> <p>Точечные обмены данными между процессами MPI-программы. Режимы буферизации.</p> <p>Проблема deadlock'ов. Коллективные взаимодействия процессов в MPI. Управление группами и коммутаторами в MPI</p>
10	<p>Тема 10. Параллельное программирование на системах с общей памятью (OpenMP)</p> <p>Рассматриваемые вопросы:</p> <p>-Введение в OpenMP</p> <p>-Стандарты программирования для систем с разделяемой памятью.</p> <p>-Создание многопоточных приложений. Использование многопоточности при программировании для многоядерных платформ.</p> <p>-Синхронизация данных между ветвями в параллельной программе. Директивы языка OpenMP</p>
11	<p>Тема 11. Параллельное программирование многоядерных GPU. Кластеры из GPU и суперкомпьютеры на гибридной схеме</p> <p>Рассматриваемые вопросы:</p> <p>-Существующие многоядерные системы.</p> <p>-GPU.</p> <p>-Использование OpenMP и MPI технологий совместно с CUDA.</p> <p>-Степень параллелизма численного алгоритма. Закон Амдала. Параллельный алгоритм решения СЛАУ</p>
12	<p>Тема 12. Программные платформы и системы для больших данных</p> <p>Рассматриваемые вопросы:</p> <p>- системы управления потоками данных</p> <p>- системы хранения больших данных</p> <p>- платформы больших данных</p> <p>- обработка больших данных в реальном времени</p>

4.2. Занятия семинарского типа.

Практические занятия

№ п/п	Тематика практических занятий/краткое содержание
1	Тема 1. Изучение технологий Hadoop и MapReduce Рассматриваемые вопросы: - Hadoop - MapReduce
2	Тема 2. Анализ больших массивов данных инструментами python Рассматриваемые вопросы: - библиотеки анализа и загрузки больших данных - фреймворки Python с параллельной обработкой данных
3	Тема 3. Высокопроизводительные вычисления с фреймворком Apache Spark Рассматриваемые вопросы: - знакомство фреймворком - знакомство с архитектурой системы - реализации концепции MapReduce - разработки программ с использованием Apache Spark
4	Тема 4. Введение в высокопроизводительные серверы на python Рассматриваемые вопросы: - работа с распределенными системами - создание кода для работы на GRU
5	Тема 5. Параллельное программирование. Параллельная обработка данных Рассматриваемые вопросы: 1. Параллельное программирование 2. Параллельная обработка данных
6	Тема 6. Работа с vCenter Server Рассматриваемые вопросы: 1. Понятие vCenter 2. Установка и развертывание vCenter
7	Тема 7. Развертывание среды для обработки данных при помощи Hadoop Рассматриваемые вопросы: 1. Обработка данных в Hadoop 2. Распределенная файловая система Hadoop 3. Разработка приложений MapReduce 4. Настройка кластера Hadoop
8	Тема 8. Составление спецификаций оборудования для работы с высокопроизводительными вычислениями Рассматриваемые вопросы: 1. Составление спецификаций оборудования для работы с высокопроизводительными вычислениями

4.3. Самостоятельная работа обучающихся.

№ п/п	Вид самостоятельной работы
1	Работа с учебной литературой
2	Участие в онлайн-конференциях и мастер-классах

№ п/п	Вид самостоятельной работы
3	Поиск алгоритмов обработки данных в открытых источниках
4	Подготовка к промежуточной аттестации.
5	Подготовка к текущему контролю.
6	Выполнение курсовой работы.
7	Подготовка к промежуточной аттестации.
8	Подготовка к текущему контролю.

4.4. Примерный перечень тем курсовых работ

1. Анализ данных с использованием алгоритмов кластеризации
2. Кластеризация данных с помощью нечетких отношений
3. Метрики, применяемые в Data mining
4. Основные стандарты Data mining
5. Направления использования эволюционных алгоритмов анализа данных
6. Анализ данных с использованием генетических алгоритмов
7. Применение методов Data mining для решения практических задач
8. Технология Knowledge Discovery in Databases (KDD)
9. Характеристики промышленных инструментальных средств Data mining
10. Использование реляционной модели построения хранилищ данных (ROLAP)
11. Использование многомерного подхода в построении хранилищ данных (MOLAP)
12. Использование гибридных (HOLAP) и виртуальных хранилищ данных
13. Технологии и методы оценки качества, очистки и предобработки анализируемых данных
14. Технология практического применения сэмпинга (sampling)
15. Сущность и направления использования аффинитивного анализа данных
16. Подходы к решению задач поиска ассоциативных правил
17. Анализ данных с использованием сети Кохонена (Kohonen network)
18. Анализ данных с использованием самоорганизующихся карт Кохонена (Self organizing map)

19. Технология анализа данных с применением регрессионных моделей
20. Технология построение и оценка значимости простой регрессионной модели
21. Характеристика алгоритмов построения деревьев решений
22. Подготовка управленческих решений на основе метода деревьев решений
23. Принципы построения и направления практического применения нейросетевых моделей
24. Подходы к анализу данных на базе ансамблей моделей
25. Применение моделей анализа временных рядов
26. Технологии обогащения данных
27. Технологии упрощения деревьев решений
28. Алгоритмы обучения нейронных сетей

5. Перечень изданий, которые рекомендуется использовать при освоении дисциплины (модуля).

№ п/п	Библиографическое описание	Место доступа
1	Флах, П. Машинное обучение. Наука и искусство построения алгоритмов, которые извлекают знания из данных / П. Флах. — Москва : ДМК Пресс, 2015. — 400 с. — ISBN 978-5-97060-273-7	https://e.lanbook.com/book/69955
2	Габдуллин, Н. М. Развитие человеческого капитала и цифровой экономики в регионах России: факторный и кластерный анализ : монография / Н. М. Габдуллин. — Казань : КФУ, 2019. — 268 с. — ISBN 978-5-00130-291-9	https://e.lanbook.com/book/173018
3	Гласснер, Э. Глубокое обучение без математики. Том 2. Практика : руководство / Э. Гласснер ; перевод с английского В. А. Яроцкого. — Москва : ДМК Пресс, 2020. — 610 с. — ISBN 978-5-97060-767-1	https://e.lanbook.com/book/131710
4	Кук, Д. Машинное обучение с использованием библиотеки H2O / Д. Кук ; перевод с английского А. Б. Огурцова. — Москва : ДМК Пресс, 2018. — 250 с. — ISBN 978-5-97060-508-0	https://e.lanbook.com/book/97353
5	Шалев-Шварц, Ш. Идеи машинного обучения : учебное пособие / Ш. Шалев-Шварц, Бен-	https://e.lanbook.com/book/131686

	ДавидШ. ; перевод с английского А. А. Слинкина. — Москва : ДМК Пресс, 2019. — 436 с. — ISBN 978-5-97060-673-5	
6	Гудфеллоу, Я. Глубокое обучение / Я. Гудфеллоу, И. Бенджио, А. Курвилль ; перевод с английского А. А. Слинкина. — 2-е изд. — Москва : ДМК Пресс, 2018. — 652 с. — ISBN 978-5-97060-618-6	https://e.lanbook.com/book/107901

6. Перечень современных профессиональных баз данных и информационных справочных систем, которые могут использоваться при освоении дисциплины (модуля).

<https://habr.com/ru> - база знаний в виде статей, обзоров

<https://journal.tinkoff.ru/short/ai-for-all/> - база данных нейронных сетей

<https://vc.ru/services/916617-luchshie-neyroseti-bolshaya-podborka-iz-top-200-ii-generatorov-po-kategoriyam> - база данных нейронных сетей

<https://github.com/abalmumcu/bert-rest-api> - профессиональная платформа для командой работы над проектов (нейронная сеть bert)

<http://library.miit.ru/> - электронно-библиотечная система Научно-технической библиотеки МИИТ

<https://proglib.io/p/raspoznavanie-obektov-s-pomoshchyu-yolo-v3-na-tensorflow-2-0-2020-11-08> - профессиональная библиотека программистов

https://yandex.cloud/ru/blog/posts/2022/12/andrey-berger-and-yandex-cloud?utm_referrer=https%3A%2F%2Fyandex.ru%2F – библиотека профессиональных статей разработчиков Яндекс

<https://yandex.cloud/ru/blog> - библиотека профессиональных статей разработчиков Яндекс

<https://tproger.ru/translations/opencv-python-guide> - библиотека основных команд OpenCV

7. Перечень лицензионного и свободно распространяемого программного обеспечения, в том числе отечественного производства, необходимого для освоения дисциплины (модуля).

Microsoft Office 2010

VMware Workstation

8. Описание материально-технической базы, необходимой для осуществления образовательного процесса по дисциплине (модулю).

1 учебный класс

Компьютер преподавателя

Компьютеры студентов

Монитор

Проектор

Экран для проектора

Маркерная доска

9. Форма промежуточной аттестации:

Курсовая работа в 5 семестре.

Экзамен в 5 семестре.

10. Оценочные материалы.

Оценочные материалы, применяемые при проведении промежуточной аттестации, разрабатываются в соответствии с локальным нормативным актом РУТ (МИИТ).

Авторы:

И.В. Зенковский

Согласовано:

Заместитель директора академии

Д.В. Паринов

Председатель учебно-методической
комиссии

Д.В. Паринов