

Минобрнауки России

Федеральное государственное бюджетное образовательное учреждение
высшего образования

«Оренбургский государственный университет»

Кафедра математики и цифровых технологий

РАБОЧАЯ ПРОГРАММА

ДИСЦИПЛИНЫ

«Б1.Д.В.2 Инфраструктура больших данных»

Уровень высшего образования

МАГИСТРАТУРА

Направление подготовки

09.04.02 Информационные системы и технологии

(код и наименование направления подготовки)

Искусственный интеллект в промышленности

(наименование направленности (профиля) образовательной программы)

Квалификация

Магистр

Форма обучения

Очная

Год набора 2024

Рабочая программа дисциплины «Б1.Д.В.2 Инфраструктура больших данных» рассмотрена и утверждена на заседании кафедры

Кафедра математики и цифровых технологий

наименование кафедры

протокол № 6 от " 19 " февраля 2024 г.

Заведующий кафедрой

Кафедра математики и цифровых технологий

наименование кафедры

А.Е. Шухман

подпись

расшифровка подписи



Исполнители:

Доцент кафедры МЦТ

должность

подпись



Ю.А. Ушаков

расшифровка подписи

СОГЛАСОВАНО:

Председатель методической комиссии по направлению подготовки

09.04.02 Информационные системы и технологии

код наименование

личная подпись

расшифровка подписи



Болодуркина И.П.

Научный руководитель магистерской программы

личная подпись

И.П. Болодуркина

расшифровка подписи

Заведующий отделом формирования фонда и научной обработки документов

личная подпись

Н.Н. Бигалиева

расшифровка подписи

Уполномоченный по качеству института

личная подпись

И.В. Крючкова

расшифровка подписи

№ регистрации _____

© Ушаков Ю.А., 2024

© ОГУ, 2024

1 Цели и задачи освоения дисциплины

Цель (цели) освоения дисциплины:

Ознакомление с основными технологиями решения задач обработки больших по объему, быстро изменяющихся и плохо структурированных данных;

Задачи:

- формирование представлений о современных методах решения задач обработки больших данных;
- формирование умения применять методы анализа больших данных;
- формирование умения реализовывать приложения для аналитики больших данных.

2 Место дисциплины в структуре образовательной программы

Дисциплина относится к обязательным дисциплинам (модулям) вариативной части блока Д «Дисциплины (модули)»

Пререквизиты дисциплины: *Б1.Д.Б.7 Объектно-ориентированные технологии и базы данных*

Постреквизиты дисциплины: *Б2.П.В.П.1 Преддипломная практика*

3 Требования к результатам обучения по дисциплине

Процесс изучения дисциплины направлен на формирование следующих результатов обучения

Код и наименование формируемых компетенций	Код и наименование индикатора достижения компетенции	Планируемые результаты обучения по дисциплине, характеризующие этапы формирования компетенций
ПК*-2 Разработка и внедрение новых методов и технологий исследования больших данных	ПК*-2-В-1 Совершенствование и разработка новых методов, моделей, алгоритмов, технологий и инструментальных средств работы с большими данными	<u>Знать:</u> принципы программно-алгоритмической обработки больших данных; <u>Уметь:</u> разрабатывать алгоритмы и программы обработки больших данных; формировать программное обеспечение <u>Владеть:</u> навыками программной реализации алгоритмов обработки больших данных;
ПК*-9 Способен руководить проектами по созданию комплексных систем на основе аналитики больших данных в различных отраслях	ПК*-9-В-1 Осуществляет руководство проектом по построению комплексных систем на основе аналитики больших данных в различных отраслях	<u>Знать:</u> способы хранения, обработки и представления данных в распределенных <u>Уметь:</u> выбирать и применять методы конфигурирования

Код и наименование формируемых компетенций	Код и наименование индикатора достижения компетенции	Планируемые результаты обучения по дисциплине, характеризующие этапы формирования компетенций
		информационных систем и оптимизации баз данных Владеть: навыками использования актуальных инструментальных средств для разработки программного обеспечения

4 Структура и содержание дисциплины

4.1 Структура дисциплины

Общая трудоемкость дисциплины составляет 3 зачетные единицы (108 академических часов).

Вид работы	Трудоемкость, академических часов	
	3 семестр	всего
Общая трудоёмкость	108	108
Контактная работа:	34,25	34,25
Лекции (Л)	18	18
Лабораторные работы (ЛР)	16	16
Промежуточная аттестация (зачет, экзамен)	0,25	0,25
Самостоятельная работа: - <i>самоподготовка: проработка и повторение лекционного материала и материала учебников и учебных пособий;</i> - <i>изучение разделов курса в системе электронного обучения;</i> - <i>подготовка к лабораторным занятиям;</i> - <i>подготовка к рубежному контролю и т.п.)</i>	73,75	73,75
Вид итогового контроля (зачет, экзамен, дифференцированный зачет)	зачет	

Разделы дисциплины, изучаемые в 3 семестре

№ раздела	Наименование разделов	Количество часов				
		всего	аудиторная работа			внеауд. работа
			Л	ПЗ	ЛР	
1	Введение в «большие данные»	26	4		4	18
2	Обработка потоков больших данных	26	4		4	18
3	Алгоритмы кластеризации больших многомерных наборов данных	26	4		4	18
4	Фреймворк Apache Spark как способ обработки больших объёмов данных	30	6		4	20
	Итого:	108	18		16	74
	Всего:	108	18		16	74

4.2 Содержание разделов дисциплины

1 Введение в «большие данные». История возникновения термина «Большие данные». Источники больших данных. Распределенные файловые системы и технология распределения-редукции. Группировка по ключу. Детали выполнения MapReduce. Комбинаторы. Обработка отказов узлов..

2 Обработка потоков больших данных. Специализированные алгоритмы для работы с данными. Система управления потоками данных. Запросы к потокам. Проблемы обработки потоков. Выборка данных из потоков. Фильтрация потоков. Алгоритм Флажол-Мартена. Оценивание моментов. Алгоритм Алона-Матиаса-Сегеди для вторых моментов.

3 Алгоритмы кластеризации больших многомерных наборов данных. Иерархическая кластеризация. Альтернативные правила управления иерархической кластеризацией. Алгоритм к-средних. Обработка данных в алгоритме BFR. Алгоритм CURE. Кластеризация для потоков и параллелизм.

4 Фреймворк Apache Spark как способ обработки больших объёмов данных. Горизонтальная масштабируемость. Основная технология распараллеливания. Кластеры среды hadoop. Особенности системы хранения. Главные конкуренты и вычислительные мощност

4.3 Лабораторные работы

№ ЛР	№ раздела	Наименование лабораторных работ	Кол-во часов
1	1	Источники больших данных. Знакомство с примерами прикладных систем добычи данных. Принцип Бонферрони.	2
2	1	Задачи распределителя. Группировка по ключу. Детали выполнения MapReduce. Комбинаторы. Обработка отказов узлов	2
3	2	Операции реляционной алгебры. Вычисление выборки с помощью MapReduce. Разбиение документов на шинглы. Хэширование документов с учетом близости. Методы для высокой степени сходства.	2
4	2	Обработка потоков данных и специализированные алгоритмы для работы с данными.	2
5	3	Система управления потоками данных. Запросы к потокам. Проблемы обработки потоков. Выборка данных из потоков. Фильтрация потоков. Алгоритм Флажол-Мартена. Оценивание моментов. Алгоритм Алона-Матиаса-Сегеди для вторых моментов.	4
6	4	Получение репрезентативной выборки. Динамическое изменение размера выборки. Анализ фильтра Блума. Комбинирование оценок. Обработка бесконечных потоков.	4
		Итого:	16

5 Учебно-методическое обеспечение дисциплины

5.1 Основная литература

1. Гергель, В. П. Современные языки и технологии параллельного программирования [Текст] : учебное пособие для студентов высших учебных заведений, обучающихся по направлениям ВПО 010400 "Прикладная математика и информатика" и 010300 "Фундаментальная информатика и информационные технологии" / В. П. Гергель; Б-ка Нижегород. гос. ун-та им. Н. И. Лобачевского. - Москва : Изд-во Моск. ун-та, 2012. - 407 с.

2. Антонов, А. С. Технологии параллельного программирования MPI и OpenMP [Текст] : учебное пособие для студентов высших учебных заведений, обучающихся по направлениям ВПО 010400 "Прикладная математика и информатика" и 010300 "Фундаментальная информатика и

5.2 Дополнительная литература

1. Воеводин В.В., Воеводин Вл.В. Параллельные вычисления. – СПб: БХВ-Петербург, 2002. – 608 с.
2. Гегель, В. П. Теория и практика параллельных вычислений : учебное пособие / В. П. Гегель. – Москва : Интернет-Университет Информационных Технологий (ИНТУИТ) : Бином. Лаборатория знаний, 2007. – 424 с. : ил.,табл. – (Основы информационных технологий). – Режим доступа: по подписке. – URL: <https://biblioclub.ru/index.php?page=book&id=233067> . – ISBN 978-5-9556-0096-3. – Текст : электронный.
3. Инструменты параллельного программирования в системах с общей памятью [Текст] : учеб. для вузов / К. В. Корняков [и др.]; под ред. В. П. Гегеля ; Нижегород. гос. ун-т им. Н. И. Лобачевского.- 2-е изд., испр. и доп. - М. : Изд-во Моск. ун-та, 2010. - 267 с.

5.3 Интернет-ресурсы

https://openedu.ru/course/hse/big_data_processing/ - «Открытое образование», Каталог курсов, MOOK: «Обработка больших данных»;

https://openedu.ru/course/misis/ABD/?session=spring_2023 - «Открытое образование», Каталог курсов, MOOK: «Введение в инженерии больших данных».

5.4 Программное обеспечение, профессиональные базы данных и информационные справочные системы

1. Операционная система РЕД ОС для рабочих станций, имеется лицензия, входит в реестр отечественного ПО.
2. «МойОфис Образование» – набор приложений для работы с текстом, таблицами и презентациями в образовательных организациях
3. Система управления учебным процессом Moodle, свободно распространяемая.
4. Программная система для организации видео-конференц-связи MTS Link
5. Программа для просмотра сайтов Яндекс.Браузер, свободно распространяемая, входит в реестр отечественного ПО.

6 Материально-техническое обеспечение дисциплины

Учебные аудитории для проведения занятий лекционного типа, семинарского типа, для проведения групповых и индивидуальных консультаций, текущего контроля и промежуточной аттестации оснащены комплектами ученической мебели, техническими средствами обучения, служащими для представления учебной информации большой аудитории. Для чтения лекций используется переносной мультимедийный комплект: ноутбук, проектор, экран.

Для проведения лабораторных занятий используются компьютерные классы, оснащенные компьютерами, объединенными в локальную сеть, подключенную через университетскую сеть к сети Интернет. Помещения для самостоятельной работы обучающихся оснащены компьютерной техникой, подключенной к сети "Интернет", и обеспечением доступа в электронную информационно-образовательную среду ОГУ.

К рабочей программе прилагаются:

- Фонд оценочных средств для проведения промежуточной аттестации обучающихся по дисциплине;
- Методические указания для обучающихся по освоению дисциплины.