



Министерство науки
и высшего образования РФ
ФГБОУ ВО «НИУ «МЭИ»
Институт дистанционного
и дополнительного образования



**АННОТАЦИИ РАБОЧИХ ПРОГРАММ ДИСЦИПЛИН (МОДУЛЕЙ)
ДОПОЛНИТЕЛЬНОЙ ОБРАЗОВАТЕЛЬНОЙ ПРОГРАММЫ**

*повышения квалификации
«Основы анализа текстовых данных»,*

Раздел(предмет) *Основы анализа данных*

Наименование дисциплин (модулей)	Содержание дисциплин (модулей)	Форма ТК	Количество часов
<i>Постановка задачи машинного обучения</i>	Типы задач, решаемых методами машинного обучения (МО). Формальная постановка задачи машинного обучения. Задачи анализа тестовой информации, решаемые методами МО. Критерии качества: аккуратность, полнота, точность, F-мера, площадь под кривой ошибок, матрица неточностей. Способы формирования выборок. Обучающая, экзаменационная и тестовая выборки. Обучение моделей. Явление переобучения модели. Несбалансированные классы. Методы борьбы с несбалансированностью: oversampling, undersampling. Специальные стратегии сэмплинга в условиях несбалансированных классов	<i>Тестирование</i>	8

Раздел(предмет) *Анализ текстовых данных (Text Mining)*

Наименование дисциплин (модулей)	Содержание дисциплин (модулей)	Форма ТК	Количество часов
<i>Особенности и задачи обработки текстовых данных</i>	Text Mining и особенности задач, связанных с анализом текстов. Онтологии и тезаурусы. Статистический подход к анализу текстовой информации. Проблема снижения размерности в задачах Text Mining. Предварительная обработка данных: стемминг, лемматизация. Слова, не несущие информации. Выявление информативных признаков. Взвешивание как способ выявления информативных терминов. Статистический подход к выявлению информативных терминов. Теоретико-информационный подход к выявлению информативных терминов. Модель представления текстовых данных в математическом виде. Модель «Мешок слов» (Bag of words). Частично- и полностью структурированные модели.	<i>Тестирование</i>	8

Раздел(предмет) ***Задача классификации текстовых документов***


Наименование дисциплин (модулей)	Содержание дисциплин (модулей)	Форма ТК	Количество часов
<i>Методы классификации данных</i>	Систематизация и обзор методов классификации. Метод ближайших соседей. Метод деревьев решений. Метод опорных векторов. Метод логистической регрессии. Наивный байесовский метод. Профильные методы классификации. Ансамблевые методы классификации. Оценка	<i>Тестирование</i>	8

Наименование дисциплин (модулей)	Содержание дисциплин (модулей)	Форма ТК	Количество часов
	разнородности методов классификации. Бустинг, бэггинг. Метод случайного леса деревьев решений.		

Раздел(предмет) *Другие задачи, решаемые в рамках Text Mining*


Наименование дисциплин (модулей)	Содержание дисциплин (модулей)	Форма ТК	Количество часов
<i>Кластеризация данных, выявление дубликатов текстовых документов</i>	Постановка задачи кластеризации, ее особенности. Иерархическая кластеризация. EM-алгоритм кластеризации. Семейство алгоритмов k-means, другие алгоритмы кластеризации. Виды дубликатов: полные дубликаты, явные дубликаты, нечеткие дубликаты. Коэффициент ассоциативности Жаккара. Семейство методов шинглов. Методы выявления дубликатов Winnowing, SpotSigs, I-Match, коэффициент Джаро-Винклера	<i>Тестирование</i>	<i>10</i>

Руководитель
ОДПО, ЦПП УВО
(должность)

	Подписано электронной подписью ФГБОУ ВО «НИУ «МЭИ»	
	Сведения о владельце ЦЭП МЭИ	
	Владелец	Максимова А.А.
	Идентификатор	R6a033f13-VoroZhtsovaAA-daecd83

А.А.
Максимова
(расшифровка подписи)

Начальник ОДПО
(должность)

	Подписано электронной подписью ФГБОУ ВО «НИУ «МЭИ»	
	Сведения о владельце ЦЭП МЭИ	
	Владелец	Крохин А.Г.
	Идентификатор	R6d4610d5-KrokhinAG-aa301f84

А.Г. Крохин
(расшифровка подписи)