

Проектное предложение

Тип элемента практической подготовки	<i>Проект</i>
Если проект, тип проекта	<i>Исследовательский</i>
Наименование проекта	R для антиковедов. Часть 2: Токенизация и разведывательный анализ
Подразделение инициатор проекта	Школа философии и культурологии
Руководитель проекта	<i>Алиева Ольга Валерьевна</i>
Основное место работы руководителя проекта в НИУ ВШЭ	Школа философии и культурологии
Контакты руководителя (адрес эл. почты)	oalieva@hse.ru
Соруководители проекта от НИУ ВШЭ (если имеются)	<i>нет</i>
Контакты соруководителей от НИУ ВШЭ (адрес эл. почты)	<i>нет</i>
Основная проектная идея / описание решаемой проблемы	<p>Проект посвящен методам токенизации в R. Токен — это отдельное наблюдение; применительно к тексту это может быть слово или сочетание слов, символ или сочетание символов, может быть даже параграф или предложение — все зависит от того, что мы намерены посчитать. Делить текст на токены мы будем с использованием различных пакетов для text-mining, научимся конвертировать данные из одного формата в другой, удалять стоп-слова, а также визуализировать результаты в ggplot2. Практическим результатом проекта станет публикация на площадке RPubs результатов анализа выбранного греческого или латинского источника (источников).</p> <p>Тематический план: 1. Абсолютная частотность (tf), визуализации в ggplot и wordclouds 2. Биграммы и построение сетей в ggraph; stopwords</p>

	<p>3. Относительная частотность (rtf) и характерные слова (tf-idf)</p> <p>4. Лексические корреляции в widyr</p> <p>5. Создание скользящего окна с пакетом slider</p> <p>6. Pointwise mutual information (PMI) в widyr</p> <p>7. Создание корпуса и работа с метаданными в пакете tm (text mining)</p> <p>8. Конвертация DTM в tidy форматы и обратно</p> <p>9. Зияния (стык гласных): как их посчитать?</p> <p>10. Считаем длину предложений (двумя способами)</p>
Цель и задачи проекта	Задачей проекта является количественный анализ выбранного античного источника или источников.
Проектное задание	Еженедельное выполнение заданий (просмотр обучающих видео, участие в обсуждениях на форуме группы, прохождение тестов), одна лабораторная работа и оценка своих peers
Планируемые результаты проекта, специальные или функциональные требования к результату	Публикация на площадке RPubs результатов анализа выбранного греческого или латинского источника (источников)
Дата начала проекта	4.07.2022
Дата окончания проекта	11.09.2022
Трудоемкость (часы в неделю) на одного участника	5
Предполагаемое количество участников (вакантных мест) в проектной команде	5
<p>Названия вакансий (ролей), краткое описание задач по каждой вакансии, количество кредитов и критерии отбора для участников проекта (<i>если характер работ для всех участников совпадает, описывается одна вакансия</i>)</p> <p><i>Кредиты на 1 участника рассчитываются по формуле:</i></p>	<p><i>Вакансия №1: участник</i></p> <p><i>Задачи:</i> еженедельное выполнение заданий (просмотр обучающих видео), участие в обсуждениях на форуме группы в LMS, прохождение тестов), одна лабораторная работа и оценка своих peers</p> <p><i>Количество кредитов: 2</i></p> <p><i>Критерии отбора на вакансию:</i> знание древнегреческого и/или латыни, курсовая/исследовательская работа в области классической</p>

<i>продолжительность в неделях * трудоемкость проекта в часах / 25</i>	античности; преимуществом будет опыт работы в проекте R для антиковедов. Часть 1: Извлечение данных из HTML & XML 10 недель * 5 часов/нед
Общее количество кредитов	<i>max 10 (5 участников по 2 кредита)</i>
Форма итогового контроля	<i>Зачет</i>
Формат представления результатов, который подлежит оцениванию	Публикация на RPubS
Формула оценки результатов, возможные критерии оценивания результатов с указанием всех требований и параметров	O_T = оценки за тестирование (max 10, считается как среднее) O_L = оценка за лабораторную работу, выставляется двумя реерами и считается как среднее $Итоговая = 0.5 * O_T + 0.5 * O_L$
Возможность пересдач при получении неудовлетворительной оценки	<i>Только для лабораторной работы</i>
Ожидаемые образовательные результаты проекта	- навыки работы с пакетами для text- mining, в том числе токенизация и подсчет частотности - визуализация данных в ggplot2
Особенности реализации проекта: территория, время, информационные ресурсы и т.п.	Дистанционно (<i>асинхронно</i>) через SmartLMS и в рабочем чате в Телеграм
Рекомендуемые образовательные программы	Филология, Философия, История, Античность, Медиевистика, Лингвистика
Требуется резюме студента	<i>Нет</i>
Требуется мотивированное письмо студента	<i>Да</i> В письме необходимо указать уровень владения древними языками (древнегреческий, латынь) и область научных интересов, включая тему курсовой работы и предполагаемые направления ее развития