

Министерство науки и высшего образования Российской Федерации
НАЦИОНАЛЬНЫЙ ИССЛЕДОВАТЕЛЬСКИЙ
ТОМСКИЙ ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ (НИ ТГУ)

Филологический факультет

УТВЕРЖДЕНО:

Декан

И. В. Тубалова

Оценочные материалы по дисциплине

Большие данные в филологических исследованиях

по направлению подготовки

45.04.01 Филология

Направленность (профиль) подготовки:

Академическая филология: современные исследовательские технологии

Форма обучения

Очная

Квалификация

Магистр

Год приема

2025

СОГЛАСОВАНО:

Руководитель ОП

Н.А. Мишанкина

Председатель УМК

Ю.А. Тихомирова

Томск – 2025

1. Компетенции и индикаторы их достижения, проверяемые данными оценочными материалами

Целью освоения дисциплины является формирование следующих компетенций:

ОПК-2 Способен использовать в профессиональной деятельности, в том числе педагогической, знания современной научной парадигмы в области филологии и динамики ее развития, системы методологических принципов и методических приемов филологического исследования.

ОПК-3 Способен владеть широким спектром методов и приемов филологической работы с различными типами текстов..

ПК-1 Выполнение отдельных заданий в рамках решения исследовательских задач в сфере филологии под руководством более квалифицированного работника.

Результатами освоения дисциплины являются следующие индикаторы достижения компетенций:

ИОПК-2.1 Демонстрирует знание современной научной парадигмы в области филологии и динамики ее развития, системы методологических принципов и методических приемов филологического исследования.

ИОПК-3.1 Демонстрирует углубленные знания в избранной конкретной области филологии и владение характерным для нее спектром методов и приемов филологической работы с различными типами текстов.

ИПК-1.1 Владеет методами и способами решения научных задач по тематике проводимого исследования, под руководством более квалифицированного работника намечает путь решения исследовательской задачи, методологию и методику исследования.

2. Оценочные материалы текущего контроля и критерии оценивания

Элементы текущего контроля:

- тесты;
- практические кейс-задания;
- аналитический отчет.

2.1. Тест (ИОПК-2.1, ИОПК-3.1)

Вариант 1

1. Какое из приведенных ниже определений наиболее точно характеризует термин «метаданные» в лингвистическом исследовании?

- а) Полные тексты художественных произведений
- б) Данные о данных: информация о тексте (автор, год издания, жанр, источник)
- в) Статистические формулы для анализа частотности слов
- г) Субъективные читательские рецензии

2. Какой тип визуализации наиболее уместен для представления динамики изменения частоты употребления слова по десятилетиям?

- а) Круговая диаграмма
- б) Линейный график
- в) Диаграмма рассеяния (scatter plot)
- г) Схема дерева

3. Что подразумевается под «очисткой данных» (data cleaning) при подготовке лингвистического датасета?

- а) Удаление всех данных, кроме имен собственных
- б) Перевод всех текстов на английский язык
- в) Приведение данных к единообразному виду (регистр, устранение опечаток, формат дат)

г) Написание литературного комментария к текстам

Ключ к тесту: 1 – б, 2 – б, 3 – в.

Критерии оценивания: тест считается пройденным на «отлично» при 100% правильных ответов, «хорошо» – при 66% (2/3), «удовлетворительно» – при 33% (1/3). Менее 33% – «неудовлетворительно».

2.2. Практическое кейс-задание (ИОПК-3.1, ИПК-1.1)

Тема: «Создание и очистка датасета для анализа лингвистических метаданных»

Задание:

Вам предоставлен CSV-файл с метаданными 150 научных статей по лингвистике, извлеченными из базы данных OPENALEX. Файл содержит ошибки и несоответствия. Используя приложение для работы с таблицами, выполните следующее:

1. Приведите названия всех журналов к единому регистру (например, нижнему).
2. Устраните дубликаты записей.
3. Столбец «Год издания» содержит текстовые и числовые значения. Приведите все значения к числовому формату, ошибочные значения удалите.
4. В столбце «Ключевые слова» разделите слова, записанные через запятую с пробелом, на отдельные ячейки с помощью инструмента «Разделить текст на столбцы».

Критерии оценивания:

«Отлично»: Все задачи выполнены полностью и корректно. Использованы адекватные инструменты (формулы, инструменты обработки). Результат представлен в виде ссылки на корректно отформатированную таблицу.

«Хорошо»: Задачи выполнены с незначительными погрешностями (например, остались неучтенные дубликаты).

«Удовлетворительно»: Выполнена только часть заданий, процесс очистки не завершен.

«Неудовлетворительно»: Задание не выполнено или выполнено неверно.

2.3. Аналитический отчет (ИОПК-2.1, ИОПК-3.1)

Тема для отчета: «Сравнительный анализ метаданных двух лингвистических журналов по выбору студента за последние 5 лет».

Структура отчета:

1. Краткое описание объекта исследования и источника данных (например, «Вопросы языкознания» и «Научный диалог» на elibrary.ru).
2. Описание методов сбора и обработки метаданных (количество статей, отобранные параметры: год, авторство, количество страниц, ключевые слова).
3. Визуализация (2-3 графика, например, распределение статей по годам, облако ключевых слов).
4. Письменная интерпретация результатов: какие выводы о фокусе, динамике развития и научной политике журналов можно сделать на основе анализа метаданных?

Критерии оценивания:

«Отлично»: Отчет имеет четкую структуру. Визуализации релевантны и технически правильно выполнены. Интерпретация глубокая, демонстрирует умение переводить данные в научные выводы.

«Хорошо»: Структура соблюдена, но интерпретация поверхностна или есть недочеты в визуализациях.

«Удовлетворительно»: Отчет формальный, интерпретация отсутствует или сводится к описанию графиков.

«Неудовлетворительно»: Отчет не представлен или не соответствует заданию.

3. Оценочные материалы итогового контроля (промежуточной аттестации) и критерии оценивания

Промежуточная аттестация по дисциплине проводится в форме зачета с оценкой и представляет собой защиту итогового кейс-проекта.

Структура итогового контроля:

Зачет проводится в устной форме. Студент представляет презентацию по результатам выполнения итогового кейс-проекта. Продолжительность презентации – 7-10 минут, продолжительность ответа на вопросы – 5-7 минут.

Тематика итоговых кейс-проектов (на выбор студента):

1. Анализ дискурса в социальных сетях: Сбор метаданных (дата, время, лайки, репосты) и текстов постов из тематического сообщества (паблика) о лингвистике/русском языке. Анализ активности аудитории и визуализация сетевых взаимодействий.
2. Эволюция терминологического поля: Анализ метаданных и ключевых слов статей из журналов по лингвистике за 10-летний период для выявления тенденций в тематике научных исследований.
3. Корпусный анализ на метауровне: Сравнение метаданных двух корпусов текстов (например, Национального корпуса русского языка и корпуса современного медиадискурса) по параметрам: источник текстов, жанровое разнообразие, временной охват.

Критерии оценивания итогового проекта:

«Отлично» (5): Исследовательский вопрос сформулирован четко и соответствует возможностям анализа метаданных. Выбор методов и инструментов сбора/анализа адекватен. Визуализации профессиональны и наглядны. Интерпретация результатов глубокая, продемонстрировано владение методологией филологического исследования.

«Хорошо» (4): Проект выполнен полностью, но интерпретация результатов недостаточно глубокая или имеются незначительные ошибки в методологии.

«Удовлетворительно» (3): Проект выполнен формально, исследовательский вопрос слишком общий, интерпретация результатов отсутствует или сводится к описанию проделанной работы.

«Неудовлетворительно» (2): Проект не представлен или не соответствует заявленной теме, методы анализа применены неверно.

Влияние текущего контроля на итоговую оценку:

Итоговая оценка выставляется на основе оценки за итоговый кейс-проект. Результаты текущего контроля (тесты, практические задания) являются допуском к зачету. Студент, не выполнивший более 50% заданий текущего контроля, к сдаче зачета не допускается.

4. Оценочные материалы для проверки остаточных знаний (сформированности компетенций)

4.1. Тест (ИОПК-2.1, ИОПК-3.1)

1. Distant reading – это методологический подход, который:

- а) Предполагает углубленное медленное чтение одного текста
- б) Основывается на количественном анализе больших массивов текстовых данных для выявления масштабных patterns
- в) Используется исключительно для анализа поэтических текстов
- г) Заменяет собой все традиционные филологические методы

2. Для визуализации взаимосвязей между соавторами научных статей наиболее подходит:

- а) Линейный график
- б) Столбчатая диаграмма (гистограмма)
- в) Сетевая диаграмма (graph)
- г) Круговая диаграмма

3. При работе с метаданными этическим принципом является:

- а) Публикация всех персональных данных авторов без ограничений
- б) Использование данных без указания источника
- в) Обеспечение конфиденциальности и анонимности там, где это необходимо
- г) Отсутствие необходимости в этических нормах при работе с данными

Ключ: 1 – б, 2 – в, 3 – в.

4.2. Практическая задача (ИПК-1.1)

Задача:

Вам поручено подготовить датасет для анализа частоты публикаций по корпусной лингвистике. В raw-файле содержится список статей с полями: `Название; Автор; Год; Журнал`.

Обнаружены ошибки: в поле «Год» для некоторых статей проставлено значение «н.д.», в поле «Журнал» один и тот же журнал назван «ВЯ», «Вопр. язык.» и «Вопросы языкознания».

Опишите последовательность действий для очистки данных и приведения их к единообразному виду.

Правильный ответ должен включать упоминание функций `НАЙТИ И ЗАМЕНИТЬ` для унификации названий, сортировки и фильтрации для поиска аномалий, условного форматирования или формул для поиска и удаления/замены значений «н.д.».

Информация о разработчиках

Кашпур Валерия Викторовна, канд. филол. наук, доцент кафедры романо-германской и классической филологии НИ ТГУ