

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

Искусственный интеллект в задачах обработки естественного языка

по направлению подготовки

45.03.03 Фундаментальная и прикладная лингвистика

Направленность (профиль) подготовки:

Фундаментальная и прикладная лингвистика

Форма обучения

Очная

Квалификация

Бакалавр

Год приема

2025

СОГЛАСОВАНО:

Руководитель ОП

А.В. Васильева

Председатель УМК

Ю.А. Тихомирова

Томск – 2025

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

Целью освоения дисциплины является формирование следующих компетенций:

ПК-4 Способен разрабатывать программный код при решении задач автоматической обработки текстов.

Результатами освоения дисциплины являются следующие индикаторы достижения компетенций:

ИПК-4.1 Применяет способы формализации и алгоритмизации поставленных задач в сфере

автоматической обработки текстов

ИПК-4.2 Создает программный код с использованием языков программирования и манипулирования данными в сфере автоматической обработки текстов

2. Оценочные материалы текущего контроля и критерии оценивания

Элементы текущего контроля:

К числу форм контроля, оценивающих уровень достижения компетенций по текущей дисциплине, относятся тесты, устные вопросы, выполнение практических заданий (ПК-4, ИПК-4.1, ИПК-4.2), контрольная и самостоятельная работы (ПК-4, ИПК-4.1).

Итоговый проект включает блок вопросов по теоретической части изучаемой дисциплины (ПК-4, ИПК-4.1, ИПК-4.2):

Пример практических задач:

Примерные задания: I. Зарегистрируйтесь на сайте Национального корпуса русского языка по адресу: <https://ruscorpora.ru/> и выполните следующие задания:

1. Как выбрать нужный подкорпус или оформить поисковый запрос в зависимости от задач исследования?

- Изучаем концепт СЧАСТЬЕ в русской языковой картине мира. Наши действия?

- Хотим отследить частотность употребления репрезентантов концепта СЧАСТЬЕ за последние два столетия.

- Социолингвистическое исследование – изучение специфики женской и мужской речи и особенности концептуализации. Концепт СЧАСТЬЕ.

- Репрезентация концепта СЧАСТЬЕ в прозе Виктории Токаревой.

- Особенности репрезентации концепта СЧАСТЬЕ в медиа картине мира за последние 10 лет. В художественной картине мира за последние 100 лет?

II. Разработайте собственный корпус, скачав массив текстов информационного новостного агентства, с учетом метарзметки и классов (дата, рубрика, автор и т.п.) , с учетом лингвистической и экстралингвистической рамок. Аргументируйте свой выбор корпуса. Придумайте гипотезу и решите, основываясь на методах количественной лингвистики, следующие задачи: частота лексем в корпусе, вхождение и сравнение лексемы или коллокатов. Результаты исследования отразите в презентации.

Пример:

```
import re
import requests
from bs4 import BeautifulSoup as bs
import pandas as pd
```

```
URL = []
```

```
with open('links_ria_kultura.txt', 'r+') as f:
```

```
    f = [line.rstrip() for line in f]
```

```
    for line in f:
```

```
        URL.append(line)
```

```

extr_title = []
extr_lead = []
extr_text = []
result = []
n = 0

def clean(extr, cleaned):
    for elm in extr:
        elm = str(elm)
        elm = re.sub('<[^\>]*>', '', elm)
        elm = re.sub('\xa0', '', elm)
        elm = re.sub('Подписывайтесь на наш канал в Яндекс.Дзен и присоединяйтесь к
нашему Telegram-каналу.', '', elm)
        elm = re.sub('Ваш браузер не поддерживает данный формат видео.', '', elm)
        cleaned.append(elm)
    x = ''.join(cleaned)
    return x

for el in URL[:50]:
    r = requests.get(el)
    page_content = r.text
    soup = bs(page_content, "html.parser")
    extr_head = soup.findAll('h1', {'class': 'article__title'})
    cleanhead = []
    head = clean(extr_head, cleanhead)

    extr_lead = soup.findAll('div', {'class': 'article__announce-text'})
    cleanlead = []
    lead = clean(extr_lead, cleanlead)

    extr_text = soup.findAll('div', {'class': 'article__text'})
    if len(extr_text) <= 0:
        extr_text = soup.find_all('p')

    cleantext = []
    news = clean(extr_text, cleantext)
    result.append([head, lead, news])
    n += 1
    print(n)
    print(news)

df = pd.DataFrame(result)
df.columns = ['Head', 'Lead', 'Text']
df['Rubric'] = 'Культура'
df.to_csv('RIA_KULTURA_1.csv')
Продумайте и разработайте web-интерфейс корпуса, интегрируйте back и фронт в
контейнер Docker.
Пример:
services:

```

```

db:
  image: mcr.microsoft.com/mssql/server:2019-latest
  environment:
    - ACCEPT_EULA=Y
    - SA_PASSWORD=YourStrong!Pass123
    - MSSQL_PID=Express
  ports:
    - "1433:1433"
  volumes:
    - sql_data:/var/opt/mssql
    - ./init.sql:/docker-entrypoint-initdb.d/init.sql
  healthcheck:
    test: ["CMD-SHELL", "/opt/mssql-tools/bin/sqlcmd -S localhost -U sa -P YourStrong!Pass123 -Q 'SELECT 1' || exit 1"]
    interval: 10s
    timeout: 5s
    retries: 20

web:
  build: .
  environment:
    - DB_SERVER=db
    - DB_NAME=Cookbook
    - DB_USER=sa
    - DB_PASSWORD=YourStrong!Pass123
  ports:
    - "5000:5000"
  depends_on:
    db:
      condition: service_healthy
  volumes:
    - ./app:/app

volumes:
  sql_data:

```

Критерии оценивания ответа на теоретический вопрос

Оценка	Критерии
	1. Понимание и логика высказывания изученного материала 2. Представление взаимосвязей процесса и взаимосвязи теоретических модулей изучаемого предмета 3. Полнота данных ответов; 4. Аргументированность данных ответов; 5. Правильность ответов на вопросы;
«отлично»	Полно и аргументировано даны ответы по содержанию задания. Обнаружено понимание материала, может обосновать свои суждения, применить знания на практике, привести необходимые примеры не только по учебнику, но и самостоятельно составленные. Изложение материала последовательно и правильно
«хорошо»	Ответы обучающегося удовлетворяют тем же требованиям,

	что и для оценки «отлично», но допускается 1-2 ошибки, которые сам же исправляет.
«удовлетворительно»	Обучающийся демонстрирует знание и понимание основных положений данного задания, но: 1) излагает материал неполно и допускает неточности в определении понятий или формулировке правил; 2) не умеет достаточно глубоко и доказательно обосновать свои суждения и привести свои примеры; 3) излагает материал непоследовательно и допускает ошибки.
«неудовлетворительно»	Демонстрация незнания ответа на соответствующее задание, допускаются ошибки в формулировке определений и правил, искажающие их смысл, беспорядочно и неуверенно излагается материал; отмечаются такие недостатки в подготовке, которые являются серьезным препятствием к успешному овладению последующим материалом.

Критерии оценивания практической работы:

Оценка	Критерии
	1. Понимание и логика алгоритма работы 2. Наличие или отсудив ошибок в коде 3. Полнота решения практических задач 4. Своевременность выполнения; 5. Умения связать практический материал с теоретическим; 6. Понимание базовых формул обработки естественного языка и программирования;
«отлично»	Основные требования к решению практических задач выполнены. Продемонстрированы умение анализировать алгоритмы и находить оптимальное количество решений, умение работать с информацией, в том числе умение затребовать дополнительную информацию, необходимую для уточнения реализации алгоритма, навыки разработки программного кода;
«хорошо»	Основные требования к решению практических задач выполнены, но при этом допущены недочеты. В частности, недостаточно раскрыты навыки стиля, недостаточно комментариев
«удовлетворительно»	Имеются существенные отступления от решения практических задач. В частности отсутствуют навык и умения моделировать решения в соответствии с заданием, представлять различные подходы к разработке алгоритмов, ориентированных на конечный результат
«неудовлетворительно»	Задача не решена, обнаруживается существенное непонимание проблемы

Итоговый проект (ПК-4, ИПК-4.1, ИПК-4.2)

Итоговый проект включает создание датасета текстов, в котором предполагается применение изученных методов с выводом цели, задач, гипотезы и результатов в виде кода и презентации

Выбор тем текстов предусматривает возможность выбора индивидуальной образовательной траектории, связывающую проектную деятельность со смежными гуманитарными дисциплинами. Однако существуют ограничительные критерии реализации проекта, направленные на формирование вышеуказанных компетенций: 1. Сбор и структуризация данных. 2. Наличие двух классов в обучающем датасете. 3. Объем материала не менее 50 тыс текстов на каждый класс. 4. Наличие формальных метрик оценивания качества результата машинного обучения

Сбор и структуризация данных предусматривает свободу выбора темы. В случае, если выбор не был осуществлен, то предлагаются следующие рубрики:

1. Новостные сайты и пресс релизы (классификация и генерация текстов по рубрике и/или информационному агентству)
2. Отзывы к товарам или фильмам (Наличие 3 класса: позитивный, негативный, нейтральный отзывы)
3. Комментарии в социальных сетях
4. Стены сообществ «ВКонтакте» (классификация по рубриками)

Критерии оценивания практической работы:

Оценка	Критерии
	1. Сформулирована гипотеза проекта 2. Собран и структурирован датасет 3. Четкая логика реализации алгоритмов обработки естественного языка в коде; 4. Правильность ответов на вопросы; 5. Наличие структурированной презентации 6. Полнота проекта
«отлично»	Выполнены все требования к проекту: сформулирована гипотеза, создан прасер сайтов для сбора и структуризации информации, написан код для обработки естественного языка Выполнены все требования к составлению презентаций: дизайн слайдов, логика изложения материала, текст хорошо написан и сформированные идеи ясно изложены и структурированы
«хорошо»	Существуют незначительные ошибки в проекте, не влияющие на конечный результат. В частности, может быть низкий уровень формальных метрик, неточности в визуализации данных Основные требования к презентациям выполнены, но при этом допущены недочеты. В частности, имеются неточности в изложении материала; отсутствует логическая последовательность в суждениях; не выдержан объем презентации
«удовлетворительно»	Существенные ошибки в коде, отсекает логика представления проекта, недостаточный объем датасета Имеются существенные отступления от требований к презентациям. В частности: тема освещена лишь частично; допущены фактические ошибки в содержании презентаций или при ответе на дополнительные вопросы.

«неудовлетворительно»	Критические ошибки в коде, гипотеза не подвержена, недостаточное количество или отсутствие обучающей выборки Тема презентации не раскрыта, обнаруживается существенное непонимание проблемы
-----------------------	--

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

Зачет в восьмом семестре состоит из трех частей.

Первая часть представляет собой тест из 20 вопросов, проверяющих ПК-4, ИПК-4.1

Ответы на вопросы первой части даются путем выбора из списка предложенных, установления соответствия между объектами или формулирования однословного ответа на вопрос открытого типа.

Примерный тест

1. Что такое токенизация?
 - A. - Процесс преобразования текста в последовательность токенов
 - B. - Процесс преобразования токенов в текст
 - C. - Процесс преобразования слов в символы
 - D. - + Процесс преобразования текста в последовательность токенов, где токеном может быть слово или символ
2. Что такое стемминг?
 - A. - Процесс преобразования слов в их базовую форму
 - B. - Процесс преобразования слов в их производные формы
 - C. - + Процесс преобразования слов в их базовую форму с отбрасыванием окончаний
 - D. - Процесс преобразования слов в символы
3. Какие алгоритмы используются для стемминга?
 - A. - + Алгоритм Портера
 - B. - Алгоритм Леммы
 - C. - Алгоритм Байеса
 - D. - Алгоритм Дамерау-Левенштейна
4. Что такое лемматизация?
 - A. - Процесс преобразования слов в их базовую форму
 - B. - + Процесс преобразования слов в их базовую форму с учетом контекста
 - C. - Процесс преобразования слов в их производные формы
 - D. - Процесс преобразования слов в символы
5. Какие алгоритмы используются для лемматизации?
 - A. - Алгоритм Портера
 - B. - Алгоритм Леммы
 - C. - + Алгоритм Mystem
 - D. - Алгоритм Дамерау-Левенштейна

6. Что такое частеречная разметка?
- A. - Процесс преобразования слов в их базовую форму
 - B. - Процесс преобразования слов в их производные формы
 - C. - + Процесс определения частей речи слов в тексте
 - D. - Процесс преобразования слов в символы
7. Какие методы используются для частеречной разметки?
- A. - Алгоритм Портера
 - B. - Алгоритм Леммы
 - C. - + Методы машинного обучения
 - D. - Алгоритм Дамерау-Левенштейна
8. Что такое морфологический анализ?
- A. - Процесс преобразования слов в их базовую форму
 - B. - Процесс преобразования слов в их производные формы
 - C. - Процесс определения частей речи слов в тексте
 - D. - + Процесс анализа грамматических и морфологических характеристик слов
9. Какие методы используются для морфологического анализа?
- A. - Алгоритм Портера
 - B. - Алгоритм Леммы
 - C. - Методы машинного обучения
 - D. - + Морфологические анализаторы, основанные на словарях и правилах
10. Что такое векторное представление слов?
- + Математическое представление слов в виде векторов
 - A. - Процесс преобразования слов в их базовую форму
 - B. - Процесс преобразования слов в их производные формы
 - C. - Процесс определения частей речи слов в тексте
11. Какие алгоритмы используются для получения векторного представления слов?
- A. - + Word2Vec
 - B. - Алгоритм Портера
 - C. - Алгоритм Леммы
 - D. - Алгоритм Дамерау-Левенштейна
12. Что такое модель языка?
- A. - Модель, используемая для обучения морфологического анализа
 - B. - Модель, используемая для обучения стемминга
 - C. - + Математическая модель, описывающая вероятность последовательности слов в языке
 - D. - Модель, используемая для обучения частеречной разметки
13. Какие методы используются для моделирования языка?
- A. - Алгоритм Портера
 - B. - Алгоритм Леммы
 - C. - + N-граммные модели
 - D. - Алгоритм Дамерау-Левенштейна
14. Что такое синтаксический анализ?

- A. - Процесс преобразования слов в их базовую форму
 - B. - Процесс преобразования слов в их производные формы
 - C. - Процесс определения частей речи слов в тексте
 - D. - + Процесс анализа синтаксической структуры предложения
15. Какие методы используются для синтаксического анализа?
- A. - Алгоритм Портера
 - B. - Алгоритм Леммы
 - C. - + Методы статистического анализа
 - D. - Алгоритм Дамерау-Левенштейна
16. Что такое машинный перевод?
- A. - Процесс преобразования слов в их базовую форму
 - B. - Процесс преобразования слов в их производные формы
 - C. - Процесс определения частей речи слов в тексте
 - D. - + Процесс автоматического перевода текста с одного языка на другой
17. Какие методы используются для машинного перевода?
- A. - Алгоритм Портера
 - B. - Алгоритм Леммы
 - C. - + Статистические модели
 - D. - Алгоритм Дамерау-Левенштейна
18. Что такое информационный поиск?
- A. - Процесс преобразования слов в их базовую форму
 - B. - Процесс преобразования слов в их производные формы
 - C. - Процесс определения частей речи слов в тексте
 - D. - + Процесс поиска и извлечения информации из больших текстовых коллекций
19. Какие методы используются для информационного поиска?
- A. - Алгоритм Портера
 - B. - Алгоритм Леммы
 - C. - + Модели вероятностного поиска
 - D. - Алгоритм Дамерау-Левенштейна
20. Что такое извлечение информации?
- A. - Процесс преобразования слов в их базовую форму
 - B. - Процесс преобразования слов в их производные формы
 - C. - Процесс определения частей речи слов в тексте
 - D. - + Процесс автоматического извлечения структурированной информации из текста

Критерии оценивания тестирования:

Оценка	Критерии
	1. Полнота выполнения тестовых заданий; 2. Своевременность выполнения; 3. Правильность ответов на вопросы; 4. Самостоятельность тестирования
«отлично»	Выполнено более 85 % заданий предложенного теста, в

	заданиях открытого типа дан полный, развернутый ответ на поставленный вопрос
«хорошо»	Выполнено более 70 % заданий предложенного теста, в заданиях открытого типа дан полный, развернутый ответ на поставленный вопрос; однако были допущены неточности в определении понятий, терминов и др.
«удовлетворительно»	Выполнено более 54 % заданий предложенного теста, в заданиях открытого типа дан неполный ответ на поставленный вопрос, в ответе не присутствуют доказательные примеры, текст со стилистическими и орфографическими ошибками.
«неудовлетворительно»	Выполнено не более 53 % заданий предложенного теста, на поставленные вопросы ответ отсутствует или неполный, допущены существенные ошибки в теоретическом материале (терминах, понятиях).

Вторая часть представляет решение практических задач (ПК-4, ИПК-4.1, ИПК-4.2):

1. Дан корпус размеченных текстов с омографами «зАмок» и «замОк». Обучите алгоритмы word2vec, FastText, модели Transformer. С помощью формальных метрик оценивания определите лучший результат

2. На основе собранного корпуса из задания 1. На основе корпуса, созданного в задании 1, обучите генеративные языковые модели для заголовков новостей.

3. Дан корпус текстов результатов футбольных матчей российской премьер-лиги. С помощью контекстно-свободных грамматик извлеките следующие сущности: команда 1 – команда 2 – результат встречи – счет.

Третья часть (ПК-4, ИПК-4.1, ИПК-4.2): предполагает выполнение итоговой проектной работы в команде с распределением ролей. Задача: дан корпус художественных текстов и комментариев пользователей к ним. Опишите корпус и создайте приложения оценки художественного произведения. Извлеките персонажей (NER), постройте между ними связи (SNA). Изучите комментарии к книгам и разработайте классификатор отзывов (Sentiment analysis)

Критерии оценивания второй и третьей практических работ идентичны и оцениваются по следующим критериями:

Оценка	Критерии
	1. Применение и понимание методов NLP 2. Наличие или отсутствия ошибок в коде 3. Полнота решения практических задач 4. Своевременность выполнения 5. Умения связать практический материал с теоретическим/ 6. Умение презентации проектного материала
«отлично»	Основные требования к решению практических задач выполнены. Продемонстрированы умение анализировать алгоритмы и находить оптимальное количество решений, умение работать с информацией, в том числе умение затребовать дополнительную информацию, необходимую для уточнения реализации алгоритма, навыки разработки

	программного кода;
«хорошо»	Основные требования к решению практических задач выполнены, но при этом допущены недочеты. В частности, недостаточно раскрыты навыки стиля, недостаточно комментариев
«удовлетворительно»	Имеются существенные отступления от решения практических задач. В частности, отсутствуют навык и умения моделировать решения в соответствии с заданием, представлять различные подходы к разработке алгоритмов, ориентированных на конечный результат
«неудовлетворительно»	Задача не решена, обнаруживается существенное непонимание проблемы

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

Первая часть. Решение тестовых задач:

Тест №1

1. Какие методы используются для извлечения информации?
 - A. - Алгоритм Портера
 - B. - Алгоритм Леммы
 - C. - Методы статистического анализа
 - D. - + Методы машинного обучения
2. Что такое автоматическая классификация текстов?
 - A. - Процесс преобразования слов в их базовую форму
 - B. - Процесс преобразования слов в их производные формы
 - C. - Процесс определения частей речи слов в тексте
 - D. - + Процесс автоматического присвоения текстам определенных категорий
3. Какие методы используются для автоматической классификации текстов?
 - A. - Алгоритм Портера
 - B. - Алгоритм Леммы
 - C. - Методы статистического анализа
 - D. - + Методы машинного обучения
4. Что такое тематическое моделирование?
 - A. - Процесс преобразования слов в их базовую форму
 - B. - Процесс преобразования слов в их производные формы
 - C. - Процесс определения частей речи слов в тексте
 - D. - + Процесс выявления скрытых тематик в текстовой коллекции
5. Какие методы используются для тематического моделирования?
 - A. - Алгоритм Портера
 - B. - Алгоритм Леммы
 - C. - + Модель LDA (Latent Dirichlet Allocation)
 - D. - Алгоритм Дамерау-Левенштейна
6. Что такое семантический анализ текста?
 - A. - Процесс преобразования слов в их базовую форму
 - B. - Процесс преобразования слов в их производные формы

- C. - Процесс определения частей речи слов в тексте
- D. - + Процесс анализа смысловых связей и значений слов и выражений

7. Какие методы используются для семантического анализа текста?

- A. - Алгоритм Портера
- B. - Алгоритм Леммы
- C. - + Методы семантической векторной близости
- D. - Алгоритм Дамерау-Левенштейна

8. Что такое определение тональности текста?

- A. - Процесс преобразования слов в их базовую форму
- B. - Процесс преобразования слов в их производные формы
- C. - Процесс определения частей речи слов в тексте
- D. - + Процесс определения позитивной, негативной или нейтральной окраски текста

9. Какие методы используются для определения тональности текста?

- A. - Алгоритм Портера
- B. - Алгоритм Леммы
- C. - + Методы машинного обучения
- D. - Алгоритм Дамерау-Левенштейна

10. Что такое генерация текста?

- A. - Процесс преобразования слов в их базовую форму
- B. - Процесс преобразования слов в их производные формы
- C. - Процесс определения частей речи слов в тексте
- D. - + Процесс автоматического создания текста компьютерной программой

11. Какие методы используются для генерации текста?

- A. - Алгоритм Портера
- B. - Алгоритм Леммы
- C. - + Рекуррентные нейронные сети
- D. - Алгоритм Дамерау-Левенштейна

12. Что такое извлечение именованных сущностей?

- A. - Процесс преобразования слов в их базовую форму
- B. - Процесс преобразования слов в их производные формы
- C. - Процесс определения частей речи слов в тексте
- D. - + Процесс выделения и классификации именованных сущностей, таких как имена людей, организаций, мест и дат

13. Какие методы используются для извлечения именованных сущностей?

- A. - Алгоритм Портера
- B. - Алгоритм Леммы
- C. - + Методы машинного обучения
- D. - Алгоритм Дамерау-Левенштейна

14. Что такое автоматическая генерация резюме?

- A. - Процесс преобразования слов в их базовую форму
- B. - Процесс преобразования слов в их производные формы
- C. - Процесс определения частей речи слов в тексте

D. - + Процесс автоматического создания краткого описания навыков и опыта из текста резюме

15. Какие методы используются для автоматической генерации резюме?

- A. - Алгоритм Портера
- B. - Алгоритм Леммы
- C. - + Методы обработки естественного языка
- D. - Алгоритм Дамерау-Левенштейна

16. Что такое автоматическое реферирование текста?

- A. - Процесс преобразования слов в их базовую форму
- B. - Процесс преобразования слов в их производные формы
- C. - Процесс определения частей речи слов в тексте
- D. - + Процесс автоматического создания краткого изложения текста

Задача 1. Разработайте программу для определения частоты встречаемости слов в тексте.

Ответ

```
f = open('pushkin-metel.txt', "r", encoding="utf-8")
```

```
text = f.read()
```

```
type(text)
```

```
str
```

```
len(text)
```

```
22968
```

```
text[:300]
```

```
# перевод в единый регистр (например, нижний)
```

```
text = text.lower()
```

```
import string
```

```
string.punctuation
```

```
'!"#$%&\'()*+,-./:;<=>?@[\\]^_`{|}~'
```

```
type(string.punctuation)
```

```
str
```

```
spec_chars = string.punctuation + '\n\xa0«»\t—...'
```

```
%%time
```

```
text = "".join([ch for ch in text if ch not in spec_chars])
```

```
Wall time: 4 ms
```

```
import re
```

```
text = re.sub("\n", "", text)
```

```
def remove_chars_from_text(text, chars):
```

```
    return "".join([ch for ch in text if ch not in chars])
```

```
%%time
```

```
text = remove_chars_from_text(text, spec_chars)
```

```
Wall time: 4.02 ms
```

```
%%time
```

```
text = remove_chars_from_text(text, string.digits)
```

```
%%time
```

```
from nltk.probability import FreqDist
```


```
fdist = FreqDist(text)
```

```
fdist
```

```
Wall time: 6.98 ms
```

```
FreqDist({'и': 146, 'в': 101, 'не': 69, 'что': 54, 'с': 44, 'он': 42, 'она': 39, 'ее': 39, 'на': 31, 'было': 27, ...})
```

```
fdist.most_common(5)
[('и', 146), ('в', 101), ('не', 69), ('что', 54), ('с', 44)]
fdist.plot(30, cumulative=False)
```



Задача 2. Создайте алгоритм для удаления стоп-слов из предложения.

Ответ:

```
from nltk.corpus import stopwords
russian_stopwords = stopwords.words("russian")
russian_stopwords.extend(['это', 'нею'])
print(len(russian_stopwords))
# russian_stopwords
153
%%time
text_tokens = [token.strip() for token in text_tokens if token not in russian_stopwords]
Wall time: 6.98 ms
print(len(text_tokens))
2158
text = nltk.Text(text_tokens)
fdist_sw = FreqDist(text)
fdist_sw.most_common(10)
Задача 3. Реализуйте функцию для токенизации слова.
from nltk import word_tokenize
text_tokens = word_tokenize(text)
print(type(text_tokens), len(text_tokens))
text_tokens[:10]
<class 'list'> 3402
['метель',
 'кони',
 'мчатся',
 'по',
 'буграм',
 'топчут',
 'снег',
 'глубокой',
 'вот',
```

```

'b']
import nltk
text = nltk.Text(text_tokens)
print(type(text))
text[:10]

```

Задача 4. Напишите программу для определения тональности текста (положительная/отрицательная).

Ответ:

```

class TextBlobWrapper():

    def __init__(self):
        self.log = logging.getLogger()
        self.is_model_trained = False
        self.classifier = None

    def init_app(self):
        self.log.info('>>>>> TextBlob initialization started')
        self.ensure_model_is_trained()
        self.log.info('>>>>> TextBlob initialization completed')

    def ensure_model_is_trained(self):
        if not self.is_model_trained:

            ds = SentimentLabelledDataset()
            ds.load_data()

            # train the classifier and test the accuracy
            self.classifier = NaiveBayesClassifier(ds.train)
            acr = self.classifier.accuracy(ds.test)
            self.log.info(str.format('>>>>> NaiveBayesClassifier trained with accuracy {}'.
acr))

            self.is_model_trained = True

        return self.classifier

```

Задача 5. Разработайте алгоритм для извлечения именованных сущностей (имена, организации, места) из текста.

```

import spacy
nlp = spacy.load('en_core_web_sm')
doc = nlp('Dogecoin is a parody cryptocurrency created by software engineer Billy
Markus and Jackson Palmer in 2013.')
for word in doc.ents:
    print(word.text, word.label_)
from spacy.tokens import Span

new_ent = Span(doc, 0, 1, label = "MONEY")
doc.set_ents([new_ent], default = 'unmodified')
for word in doc.ents:
    print(word.text, word.label_)

```

Задача 6. Создайте модель классификации текстов на заданное количество категорий.

```

documents = []

from nltk.stem import WordNetLemmatizer

stemmer = WordNetLemmatizer()

for sen in range(0, len(X)):
    # Remove all the special characters
    document = re.sub(r'\W', ' ', str(X[sen]))

    # remove all single characters
    document = re.sub(r'\s+[a-zA-Z]\s+', ' ', document)

    # Remove single characters from the start
    document = re.sub(r'^[a-zA-Z]\s+', ' ', document)

    # Substituting multiple spaces with single space
    document = re.sub(r'\s+', ' ', document, flags=re.I)

    # Removing prefixed 'b'
    document = re.sub(r'^b\s+', '', document)

    # Converting to Lowercase
    document = document.lower()

    # Lemmatization
    document = document.split()

    document = [stemmer.lemmatize(word) for word in document]
    document = ' '.join(document)

    documents.append(document)

```

from sklearn.feature_extraction.text import CountVectorizer

```

vectorizer = CountVectorizer(max_features=1500, min_df=5, max_df=0.7,
stop_words=stopwords.words('english'))
X = vectorizer.fit_transform(documents).toarray()
Term frequency = (Number of Occurrences of a word)/(Total words in the document)
IDF(word) = Log((Total number of documents)/(Number of documents containing the
word))

```

from sklearn.feature_extraction.text import TfidfTransformer

```

tfidfconverter = TfidfTransformer()
X = tfidfconverter.fit_transform(X).toarray()
from sklearn.feature_extraction.text import TfidfVectorizer
tfidfconverter = TfidfVectorizer(max_features=1500, min_df=5, max_df=0.7,
stop_words=stopwords.words('english'))
X = tfidfconverter.fit_transform(documents).toarray()
from sklearn.model_selection import train_test_split
X_train, X_test, y_train, y_test = train_test_split(X, y, test_size=0.2, random_state=0)

```

Задача 7. Напишите программу для определения языка текста.

Ответ:

```

from polyglot.detect import Detector

```

```

mixed_text = u"""
China (simplified Chinese: 中国; traditional Chinese: 中國),
officially the People's Republic of China (PRC), is a sovereign state
located in East Asia.
"""

for language in Detector(mixed_text).languages:
    print(language)

# name: English   code: en   confidence: 87.0 read bytes: 1154
# name: Chinese   code: zh_Hant confidence: 5.0 read bytes: 1755
# name: un        code: un   confidence: 0.0 read bytes: 0

```

Задача 8. Разработайте алгоритм для извлечения ключевых слов из текста.

Ответ:

```

from multi_rake import Rake

text_en = (
    текст.'
)

rake = Rake()

keywords = rake.apply(text_en)

print(keywords[:10])

```

Задача 9. Создайте модель генерации текста на основе заданного контекста.

```

pip3 install tensorflow==2.0.1 numpy requests tqdm
import tensorflow as tf
import numpy as np
import os
import pickle
from tensorflow.keras.models import Sequential
from tensorflow.keras.layers import Dense, LSTM, Dropout
from string import punctuation
sequence_length = 100
BATCH_SIZE = 128
EPOCHS = 30
# dataset file path
FILE_PATH = "data/wonderland.txt"
BASENAME = os.path.basename(FILE_PATH)
# read the data
text = open(FILE_PATH, encoding="utf-8").read()
# remove caps, comment this code if you want uppercase characters as well
text = text.lower()
# remove punctuation
text = text.translate(str.maketrans("", "", punctuation))

# print some stats
n_chars = len(text)
vocab = ".join(sorted(set(text)))

```

```
print("unique_chars:", vocab)
n_unique_chars = len(vocab)
print("Number of characters:", n_chars)
print("Number of unique characters:", n_unique_chars)
```

Информация о разработчиках

Степаненко Андрей Александрович, старший преподаватель кафедры общей, компьютерной и когнитивной лингвистики