

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

Филологический факультет

УТВЕРЖДЕНО:

Декан

И. В. Тубалова

Рабочая программа учебной практики

**Проектно-технологическая практика**

по направлению подготовки

**45.04.03 Фундаментальная и прикладная лингвистика**

Направленность (профиль) подготовки:  
**«Компьютерная и когнитивная лингвистика»**

Форма обучения

**Очная**

Квалификация

**Магистр**

Год приема

**2024**

СОГЛАСОВАНО:

Руководитель ОП

З.И. Резанова

Председатель УМК

Ю.А. Тихомирова

## **1. Цель практики**

Целями учебной практики по получению первичных умений и навыков являются: закрепление теоретических знаний и приобретение практических навыков, полученных при изучении базовых дисциплин; изучение организационной структуры лаборатории (далее предприятия) и действующих на нем систем управления; ознакомление с содержанием основных работ и исследований, выполняемых на предприятии или организации по месту прохождения практики.

Цели направлены на формирование следующих компетенций:

УК-2 Способен управлять проектом на всех этапах его жизненного цикла

УК-3 Способен организовывать и руководить работой команды, вырабатывая командную стратегию для достижения поставленной цели

УК-4 Способен применять современные коммуникативные технологии, в том числе на иностранном(ых) языке(ах), для академического и профессионального взаимодействия

УК-6 Способен определять и реализовывать приоритеты собственной деятельности и способы ее совершенствования на основе самооценки

ОПК-1 Способен решать профессиональные задачи, применяя основные понятия, категории и положения лингвистических теорий и актуальные концепции в области лингвистики

ОПК-2 Способен анализировать, сопоставлять и критически оценивать различные лингвистические направления, теории и гипотезы при решении задач профессиональной деятельности

ОПК-3 Способен выбирать оптимальные подходы и методы решения конкретных научных и прикладных задач в области лингвистики и информационных технологий

ОПК-4 Способен расширять сферу научной деятельности, участвовать в междисциплинарных исследованиях на стыке наук

ПК-1 Способен проводить самостоятельные исследования и получать новые научные результаты в области междисциплинарных лингвистических исследований

ПК-2 способность самостоятельно планировать и проводить научные эксперименты (в том числе, при наличии подобного оборудования, с использованием высокоточных методов регистрации мозговой активности и движений глаз)

ПК-3 способность разрабатывать системы автоматической обработки звучащей речи и письменного текста на естественном языке, лингвистические компоненты электронных ресурсов и интеллектуальных электронных систем (лингвистические корпуса, словари, онтологии, базы данных)

ПК-4 способность разрабатывать проекты прикладной направленности в области когнитивной и компьютерной лингвистики с применением современных технических средств и информационных технологий, в том числе в области искусственного интеллекта.

## **2. Задачи практики**

Задачами учебной практики по получению первичных знаний и умений являются – – Изучить организационную структуру базы практики как объекта информатизации, его особенности функционирования. (ИУК-4.2)

– Изучить особенности имеющихся на предприятии информационных систем, а также сбора, обработки, структуризации и передачи информации (ИУК-4.2, ИУК-4.1, УК-4).

– Собрать учебный материал для выполнения выпускных работ в процессе дальнейшего обучения в ВУЗе (ОПК-3, ИОПК-3.3, ПК-2, ИПК-2.2, ИПК-2.3, ПК-3, ИПК-3.1, ПК-4, ИПК-4.3). В частности:

-обработка текстов на естественном языке в научных целях (лингвистическая разметка, глоссирование, аннотирование, рубрикация, реферирование, редактирование);  
-планирование, организация, проведение и обработка данных психолингвистических экспериментов;  
-планирование организация сбора и обработки данных психолингвистических экспериментов;  
-разработки, совершенствования и корректирования содержания электронных языковых ресурсов (текстовых, речевых и мультимодальных корпусов, словарей, тезаурусов, фонетических, лексических, грамматических и иных баз данных и баз знаний);  
-сбор и структуризация таксового массива данных с целью формирования базы для дальнейшего исследования;  
-обработка естественного языка современными методами компьютерной лингвистики.

### **3. Место практики в структуре образовательной программы**

Практика относится к обязательной части образовательной программы.

### **4. Семестр(ы) освоения и форма(ы) промежуточной аттестации по практике**

Семестр 1, зачет.

Семестр 2, зачет с оценкой.

### **5. Входные требования для освоения практики**

Для успешного освоения практики требуются результаты обучения по следующим дисциплинам: «Основные направления лингвистического обеспечения новых информационных технологий», «Профессиональный иностранный язык», «Статистические методы в гуманитарных исследованиях», «Экспериментальные методы лингвистического исследования», «Психолингвистика», «Язык программирования Python», «Язык программирования R».

### **6. Способы и формы проведения практики**

Практика проводится на базе ТГУ – Лаборатория лингвистической антропологии, лаборатория «Когнитивные исследования языка». Способы проведения: стационарная.

Форма проведения: распределенная.

### **7. Объем и продолжительность практики**

Объем практики составляет 6 зачётных единицы, 216 часов, из которых:

– лекции: 0 ч.;

– иная контактная работа: 6,8 ч.

Объем самостоятельной работы студента определен учебным планом.

Практика проводится в форме практической подготовки.

Продолжительность практики составляет 38 недель.

### **8. Планируемые результаты практики**

Результатами прохождения практики являются следующие индикаторы достижения компетенций:

ИУК-2.3 - Обеспечивает выполнение проекта в соответствии с установленными целями, сроками и затратами;

ИУК-3.1 Формирует стратегию командной работы на основе совместного обсуждения целей и направлений деятельности для их реализации;

ИУК-3.2 Организует работу команды с учетом объективных условий (технология, внешние факторы, ограничения) и индивидуальных возможностей членов команды;

ИУК-3.3 Обеспечивает выполнение поставленных задач на основе мониторинга командной работы и своевременного реагирования на существенные отклонения.

ИУК-4.1 Обосновывает выбор актуальных коммуникативных технологий (информационные технологии, модерирование, медиация и др.) для обеспечения академического и профессионального взаимодействия;

ИУК-4.2 Применяет современные средства коммуникации для повышения эффективности академического и профессионального взаимодействия, в том числе на иностранном (ых) языке (ах);

ИУК-4.3 Оценивает эффективность применения современных коммуникативных технологий в академическом и профессиональном взаимодействиях;

ИУК-6.1 - Разрабатывает стратегию личностного и профессионального развития на основе соотнесения собственных целей и возможностей с развитием избранной сферы профессиональной деятельности;

ИУК-6.3 - Оценивает результаты реализации стратегии личностного и профессионального развития на основе анализа (рефлексии) своей деятельности и внешних суждений;

ИОПК-1.2 - Решает профессиональные задачи применяя основные понятия, категории и положения лингвистических теорий;

ИОПК-2.3 - Совершает выбор лингвистического направления, теории на основе их самостоятельного поиска и анализа, сопоставления, критической оценки при решении задач профессиональной деятельности;

ИОПК-3.3 - Способен решать конкретные научные и прикладные задачи в области лингвистики и информационных технологий на основе самостоятельного выбора оптимальных подходов и методов их решения;

ИОПК-4.3 - Способен участвовать в исследованиях и прикладных проектах в сфере междисциплинарного взаимодействия лингвистики и наук гуманитарного, математического и естественно-научного циклов;

ИПК-1.3 - Последовательно реализует исследовательскую программу, получает новые научные результаты;

ИПК-2.2 - Применяет имеющееся программное обеспечение и оборудование при проведении экспериментов в соответствии с технологическими возможностями для достижения цели исследования.

ИПК-2.3 Проводит экспериментальные исследования в соответствии с этическими нормами взаимодействия с респондентами, хранения и обработки данных.

ИПК-2.4 Применяет методы статистической обработки полученных экспериментальных данных и осуществляет их интерпретацию в соответствии с имеющимися теориями;

ИПК-3.1 - Разрабатывает системы автоматической обработки звучащей речи и письменного текста на естественном языке.

ИПК-3.2 - Разрабатывает лингвистические компоненты электронных ресурсов (лингвистические корпуса, словари);

ИПК-4.3 - Обеспечивает выполнение проекта в области когнитивной и компьютерной лингвистики с применением современных технических средств и информационных технологий, в том числе в области искусственного интеллекта, в соответствии с установленными целями, сроками и затратами.

## **9. Содержание практики**

<b>Этапы практики</b>	<b>Виды работ, связанные с будущей профессиональной деятельностью</b>	<b>Часы всего (в т.ч. контактные)</b>
1. Организационный	1. Проведение собрания по организации практики:	4 (2)

	<ul style="list-style-type: none"> <li>– знакомство с целями, задачами, требованиями к практике и формами отчетности по практике (программой практики);</li> <li>– знакомство с графиком проведения практики;</li> <li>– подготовка дневников практиканта.</li> </ul>	
2. Ознакомительный	<p>1. Знакомство с правилами внутреннего распорядка и иными локальными нормативными актами ТГУ.</p> <p>2. Инструктаж по технике безопасности и охране труда, соблюдению правил противопожарной безопасности, санитарно-эпидемиологических правил и гигиенических нормативов в ТГУ</p> <p>3. Знакомство с проектной деятельностью лаборатории, ее целью и задачами, актуальными проектами.</p>	4 (2)
3. Проектный	<p>В зависимости от специализации студента, текущих целей лаборатории может применен дифференцированный подход формировании задач практики, учитывающий развитие компетенций, предусмотренной текущей программой практики</p> <p>Производственный этап может включать следующую проектную деятельность:</p> <p>1. Создание корпуса устной речи носителей русско-тюркского билингвизма (ИУК-2.3, ИПК-2.2, ИПК-2.3, ИПК-4.3, ИУК-4.1, ИУК-4.2)</p> <p>Изучение литературы по корпусной лингвистике, знакомство с теоретическим обоснованием и особенностями создаваемой в проекте Лаборатории лингвистической антропологии.</p> <p>1. Формирование реестра билингвов, носителей русско-тюркского билингвизма информантов;</p> <p>2. Проведение анкетирования билингвов на основании социолингвистической и психолингвистической анкет.</p> <p>3. Архивация данных анкет.</p> <p>4. Записи устной речи носителей русско-тюркского билингвизма для формирования создаваемого в проекте Лаборатории лингвистической антропологии корпуса</p> <p>5. Транскрибирование записей устной речи носителей русско-тюркского билингвизма.</p> <p>6. Автоматическая разметка текстов записей устной речи носителей русско-тюркского билингвизма.</p> <p>7. Ручная правка автоматической разметки текстов записей устной речи носителей русско-тюркского билингвизма.</p> <p>8. Ручная разметка отклонений от речевого стандарта в текстах записей устной речи носителей русско-тюркского билингвизма.</p>	96 (4)

	<p>II. Создание психолингвистической базы данных (ИУК-2.3, ИОПК-2.3, ИОПК-3.3, ИОПК-4.3, ИПК-2.2, ИПК-2.3, ИПК-4.3, ИУК-4.1, ИУК-4.2)</p> <ol style="list-style-type: none"> <li>1. Знакомство с принципами создания психолингвистических баз данных, с теоретическими основами психолингвистической базы данных, создаваемой в настоящее время в Лаборатории лингвистической антропологии.</li> <li>2. Проведение анкетирования с целью выявления оценки отражения в семантике языковых пяти модальностей.</li> <li>3. Архивация полученных данных</li> <li>4. Разработка программного кода базы данных.</li> <li>5. Создание интерфейса психолингвистической базы данных.</li> </ol> <p>III. Проведение психолингвистических экспериментов, направленных на выявление разных аспектов взаимодействия языков в процессах порождения и восприятия речи. (ИУК-2.3, ИОПК-2.3, ИОПК-3.3, ИПК-2.2, ИПК-2.3, ИПК-4.3, ИУК-4.1, ИУК-4.2)</p> <ol style="list-style-type: none"> <li>1. Знакомство с принципами проведения поведенческих психолингвистических экспериментов, изучение литературы.</li> <li>2. Знакомство с принципами работы этического комитета Международного центра исследований развития человека.</li> <li>3. Участие в организации и проведении психолингвистических экспериментов в качестве испытуемых</li> <li>4. Организация и проведение психолингвистических экспериментов в разных группах испытуемых</li> <li>5. Подготовка стимульного материала для проведения психолингвистических экспериментов разного типа.</li> <li>6. Разработка скриптов для проведения поведенческих экспериментальных исследований языка при помощи специализированного программного обеспечения E-Prime, окулографического оборудования.</li> <li>7. Обработка и интерпретация полученных данных.</li> </ol> <p>IV. Парсинг и структуризация данных (ИУК-2.3, ИПК-3.1, ИПК-4.3, ИУК-4.1, ИУК-4.2)</p> <ol style="list-style-type: none"> <li>1. Подготовительный этап.</li> <li>2. Постановка задачи и выбор источников парсинга</li> <li>3. Написание программного кода для выбранного сайта</li> <li>4. Набор данных в соответствии с</li> </ol>	
--	---	--

	<p>поставленными целями</p> <p>5. Структуризация скаченных данных в виде таблиц с метаинформацией</p> <p>6. Препроцессинг скаченных массивов</p> <p>V. Извлечение фактов из текста (ИУК-2.3, ИПК-3.1, ИПК-4.3, ИУК-4.1, ИУК-4.2)</p> <p>1. Подготовительный этап</p> <p>2. Ознакомление с формальными грамматиками</p> <p>3. Знакомство с современным ПО</p> <p>4. Написание основных правил</p> <p>5. Процесс извлечения фактов (написание правил, словарей)</p> <p>VI. Анализ скаченных или предоставленных текстов (ИУК-2.3, ИПК-3.1, ИПК-4.3, ИУК-4.1, ИУК-4.2)</p> <p>1. Подготовительный этап</p> <p>2. Аналитика скаченных текстов в соответствии с текущими задачами лаборатории</p> <p>VII. Искусственный интеллект в задачах обработки естественного языка</p> <p>1. Структуризация данных</p> <p>2. Предобработка текстовых данных</p> <p>3. Генеративные модели</p> <p>4. Модели суммаризации</p> <p>5. ИИ в задачах классификации</p> <p>6. Формальные метрики оценивания моделей</p> <p>7. Обработка звучащей речи: модели vosk и whisper</p>	
5. Заключительный	<p>1. Подготовка отчета и подготовка материалов, необходимых для его защиты (презентация, методическая разработка и т.д.).</p> <p>2. Защита отчета по итогам практики.</p>	4 (2)

## 10. Формы отчетности по практике

По итогам прохождения практики обучающиеся в срок до завершения периода практики по календарному графику предоставляют руководителю практики от ТГУ:

- заполненный дневник практики;
- отчет о прохождении практики с приложениями, в которых включены этапы выполнения практических заданий (программный код, работа с экспериментами и пр.);
- программный код в соответствии с поставленными задачами;
- дизайны экспериментов;
- результаты обработки текстовых массивов данных;
- результаты проведенных экспериментов;
- иные виды работ, предусмотренные в рамках практики в лаборатории.

## 11. Организация промежуточной аттестации обучающихся

### 11.1 Порядок и форма проведения промежуточной аттестации

Промежуточная аттестация проводится в форме зачета с оценкой путем публичной защиты обучающимися индивидуальных отчетов о прохождении практики на итоговом

учебном занятии перед комиссией из не менее трех научно-педагогических работников, включая руководителя практики от ТГУ.

#### 11.2 Процедура оценивания результатов обучения

Оценка сформированности результатов обучения осуществляется руководителем практики (комиссией) на основе анализа предоставленных отчетных документов, выступления обучающегося и его ответов на вопросы. Подведение итогов по этапам проведения (разделам) практики осуществляется по следующим критериям: а) практическая подготовленность обучающегося к решению конкретных профессиональных задач (соответствующих формируемым компетенциям); б) рефлексивность обучающегося: способность критически оценивать свою работу в ходе практики (в том числе – с точки зрения этических норм, в аспекте собственного личностного роста, с точки зрения возможности применения полученного опыта в предстоящей профессиональной деятельности и т.д.); в) сформированность универсальных / общекультурных компетенций, проявляющихся в том числе в своевременности, аккуратности и полноте выполнения всех видов работ на протяжении всех этапов практики, предусмотренных настоящей программой. Результаты текущего контроля каждого обучающегося отражаются в его дневнике практики, заверяются подписью руководителя практики.

Обучающиеся, не выполнившие программу практики без уважительной причины или получившие отрицательную оценку, считаются имеющими академическую задолженность и обязаны ликвидировать академическую задолженность в порядке, установленном в локальных документах Университета.

#### 11.3 Критерии оценивания результатов обучения

Результаты прохождения практики определяются оценками «отлично», «хорошо», «удовлетворительно», «неудовлетворительно» / «зачтено», «незачтено». Результат прохождения практики может оценен на «отлично» (зачтено), если программа практики выполнена в полном объеме; практическая деятельность проведена на высоком научном и организационно-методическом уровне, формулировались и эффективно решались практические задачи, рационально применялись разнообразные методы и приемы практической деятельности; студент проявил глубокое знание теоретического материала и творческую самостоятельность в подборе материала при построении, проведении и анализе отчетной документации; студент показал в полной мере личностные качества специалиста в области компьютерной и когнитивной лингвистики; своевременно предоставил качественно оформленную отчетную документацию по практике, в которой предоставлен глубокий анализ результатов практики. Компетенции, закреплённые за практикой, сформированы на уровне – высокий

Оценка «Хорошо» (зачтено). Программа практики выполнена в полном объеме; практическая деятельность проведена на высоком научном и организационно-методическом уровне; однако недостаточно эффектно формулировались и решались практические задачи, применялись разнообразные методы и приемы практической деятельности; студент показал достаточные знания теоретического материала, самостоятельность в подборе материала при построении, проведении и анализе отчетной документации; достаточно успешно справляется с выполнением исследовательских процедур и на теоретическом, и на эмпирическом уровне (осознанно и грамотно); своевременно предоставил качественно оформленную отчетную документацию по практике. К недостаткам можно отнести: содержание предоставленной отчетной документации характеризуется недостаточно глубоким самоанализом деятельности. Компетенции, закреплённые за практикой, сформированы на уровне – хороший(средний)

Оценка «Удовлетворительно» (зачтено). Недостаточно эффективно применял теоретические, методологические и технологические методы и приемы, слабо активизировал познавательную деятельность, не всегда мог выполнить поставленные практические задачи (ошибки в коде, неточности и ошибки в проектировании и проведении экспериментов), при анализе собственной практической деятельности не видел своих



ошибок и недостатков; допущены серьезные ошибки при заполнении отчетной документации; нерационально организовывал свою практическую деятельность на рабочем месте в учреждении-базе практики; выявлена неорганизованность и недостаточная ответственность в практической деятельности; студент пропустил запланированные виды работ, без уважительной причины; может ориентироваться в основных характеристиках исследования, допуская при этом ошибки в трактовках и формулировании конкретных положений. Может действовать только по образцу; несвоевременно представил отчетную документацию, которая характеризуется неглубоким анализом, поверхностностью и тезисностью изложения итогов прохождения практики. Компетенции, закреплённые за практикой, сформированы на уровне – достаточный.

Оценка «неудовлетворительно» (не зачтено). Не может самостоятельно выполнять задания; студент не явился на занятие без уважительной причины и без предупреждения; студент проявил безответственность, недисциплинированность, халатность в ходе практики; не предоставил отчетную документацию. Компетенции, закреплённые за практикой, сформированы на недостаточном уровне или не сформированы.

## **12. Учебно-методическое обеспечение**

а) Электронный учебный курс по практике в электронном университете «Moodle» - <https://moodle.tsu.ru/course/view.php?id=14659>

б) Оценочные материалы текущего контроля и промежуточной аттестации по практике.

в) Методические указания по подготовке отчета по практике.

Практика является составной частью основной профессиональной образовательной программы подготовки обучающегося и обеспечивает профессионально-практическую подготовку студентов на базах практики: организациях и структурных подразделениях ТГУ. Обучающиеся в период прохождения практики: выполняют индивидуальные задания, предусмотренные программами практики; соблюдают правила внутреннего трудового распорядка; соблюдают требования охраны труда и пожарной безопасности. Обучающийся, не вышедший на базу практики и не выполнивший программу практики по уважительной причине. При подведении итогов (при промежуточной аттестации по практике) такому обучающемуся оценка автоматически снижается на один балл (по 5-балльной шкале). Обучающийся, приступивший к практике, однако систематически нарушающий учебную дисциплину (срыв запланированных диагностических, коррекционных и иных мероприятий, выход на базу без необходимой подготовки к выполнению практических заданий и т.д.), не соблюдающий внутренний распорядок базы и этические нормы профессиональной деятельности, снимается с базы практики, не аттестуется по практике и представляется к отчислению как не выполнил программу практики без уважительных причин

Обучающийся не выполнил программу практики без уважительных причин, или не представил отчёт о практике в установленный приказом срок, или при защите отчёта по практике на Комиссии получил неудовлетворительную оценку, подлежит отчислению из университета за невыполнение обязанностей по добросовестному освоению основной профессиональной образовательной программы и выполнению учебного плана.

г) Методические указания по организации самостоятельной работы студентов.

Формы самостоятельной работы студентов разнообразны. Они включают в себя:

- изучение и систематизацию практических и теоретических примеров в рамках выполнения текущих заданий по предмету;
- изучение учебной, научной и методической литературы, материалов периодических изданий с привлечением электронных средств официальной, статистической, периодической и научной информации;
- подготовку докладов и презентаций, написание программного кода и его отладка;

– участие в работе студенческих конференций, комплексных научных исследованиях.

Самостоятельная работа приобщает студентов к научному творчеству, поиску и решению актуальных современных проблем.

Примеры самостоятельной работы студентов:

Создание словаря и его частотного распределения в текстах (пример):

```
library(readxl)
#library(quanteda.sentiment)
library(quanteda)
# install.packages("remotes")
# remotes::install_github("quanteda/quanteda.sentiment")
tmp <- read_excel("full_word_rating_after_coding.xlsx", col_names = TRUE)
```

```
df #head body stem class
mycorp <- corpus(df, text_field = "stem", )
```

```
dict2 <- dictionary(list(neg = c(tmp$word[tmp$value < 0]),
                           neut = c(tmp$word[tmp$value == 0]),
                           pos = c(tmp$word[tmp$value > 0])))
```

```
sent_pres <- mycorp_vk %>%
  corpus_subset(gnd == "f")
```

```
sent_pres2 <- mycorp_vk %>%
  corpus_subset(gnd == "m")
```

```
summary(mycorp_vk)
```

```
x_m <- tokens_lookup(tokens(sent_pres), dictionary = dict2) %>%
  dfm()
```

```
x_f <- tokens_lookup(tokens(sent_pres2), dictionary = dict2) %>%
  dfm()
```

```
x_m <- dfm_weight(x_m, scheme = "prop")
```

```
x_f <- dfm_weight(x_f, scheme = "prop")
```

```
x_full <- tokens_lookup(tokens(mycorp_vk), dictionary = dict2) %>%
  dfm()
```

```
x_f <- convert(x_f, to = "data.frame")
```

```
x_m <- convert(x_m, to = "data.frame")
```

```
x_m$gnd <- "f"
```

```
x_f$gnd <- "m"
```

```
x_full_abs_vkwall <- rbind(x_f, x_m)
```

```
x_full_abs_vkwall$ComType <- "vkwall"
```

```
write.csv(x_full_abs_vkwall, "sentiment_vkwall_gnd.csv")
```

```
ggplot(x_full_abs_vkwall, aes(doc_id, neut, fill = gnd, group = gnd)) +
  geom_bar(stat='identity', position = position_dodge(), size = 1) +
```

```
scale_fill_brewer(palette = "Set1") +
```

```
  theme(axis.text.x = element_text(angle = 45, vjust = 1, hjust = 1)) +
```

```
  ggtitle("Sentiment scores in twelve Sherlock Holmes novels") + xlab("")
```

```
x_m2 <- convert(x_m, to = "data.frame")
```

```
x_m2 <- as.data.frame(x_m)
```

```
x_f2 <- convert(x_f, to = "data.frame")
```

```
x_f2 <- as.data.frame(x_f)
```

Корреляционный анализ:

```
library(outliers)
```

```
grubbs.test(emot_int$neg, type = 10)
```

```
grubbs.test(emot_int$pos, type = 10)
```

```

grubbs.test(emot_int$neut, type = 10)
library(ggplot2)
p = ggplot(emot_int[, -1], aes(x=self))
(p <- p+geom_density(aes(fill=gnd), alpha=1/2))

# Sample data
data <- emot_int[, 2:4] # Numerical variables
groups <- as.factor(emot_int[, 5]) # Factor variable (groups)
# Plot correlation matrix
pairs(data)

# Equivalent with a formula
pairs(~ neg+pos+neut, data = emot_int)

pairs(data,          # Data frame of variables
      labels = colnames(data), # Variable names
      pch = 1,          # Pch symbol
      bg = rainbow(2)[groups], # Background color of the symbol (pch 21 to 25)
      col = rainbow(2)[groups], # Border color of the symbol
      main = "",        # Title of the plot
      rowlattop = TRUE,  # If FALSE, changes the direction of the diagonal
      gap = 1,          # Distance between subplots
      cex.labels = NULL, # Size of the diagonal text
      font.labels = 1)   # Font style of the diagonal text

panel.hist <- function(x, ...) {
  usr <- par("usr")
  on.exit(par(usr))
  par(usr = c(usr[1:2], 0, 1.5))
  his <- hist(x, plot = FALSE)
  breaks <- his$breaks
  nB <- length(breaks)
  y <- his$counts
  y <- y/max(y)
  rect(breaks[-nB], 0, breaks[-1], y, col = rgb(0, 1, 1, alpha = 0.5), ...)
  # lines(density(x), col = 2, lwd = 2) # Uncomment to add density lines
}

# Creating the scatter plot matrix
pairs(data,
      upper.panel = NULL,      # Disabling the upper panel
      diag.panel = panel.hist) # Adding the histograms
# Function to add correlation coefficients
panel.cor <- function(x, y, digits = 2, prefix = "", cex.cor, ...) {
  usr <- par("usr")
  on.exit(par(usr))
  par(usr = c(0, 1, 0, 1))
  Cor <- abs(cor(x, y)) # Remove abs function if desired
  txt <- paste0(prefix, format(c(Cor, 0.123456789), digits = digits)[1])
  if(missing(cex.cor)) {
    cex.cor <- 0.4 / strwidth(txt)
  }
}

```

```

    }
    text(0.5, 0.5, txt,
        cex = 1 + cex.cor * Cor) # Resize the text by level of correlation
    }

# Plotting the correlation matrix
pairs(data,
      upper.panel = panel.cor, # Correlation panel
      lower.panel = panel.smooth) # Smoothed regression lines

# install.packages("gclus")
library(gclus)

# Correlation in absolute terms
corr <- abs(cor(data))

colors <- dmat.color(corr)
order <- order.single(corr)

cpairs(data, # Data frame of variables
      order, # Order of the variables
      panel.colors = colors, # Matrix of panel colors
      border.color = "grey70", # Borders color
      gap = 0.45, # Distance between subplots
      main = "Ordered variables colored by correlation", # Main title
      show.points = TRUE, # If FALSE, removes all the points
      pch = 21, # pch symbol
      bg = rainbow(2)[groups]) # Colors by group

```

Пример работы по генерации заголовков новостей. Скачайте датасет новостей `riatomsk.csv`. В колонках есть следующие атрибуты: «lead» - лид новости, «title» -заголовок новости, «body» - тело новости. Обучите модель RuGPT-3 с целью генерации заголовка новости. Загрузите полученный код в муди, прикрепите сгенерированные примеры заголовков в формате `.txt`.

Пример кода:

```

%%writefile setup.sh
git clone https://github.com/NVIDIA/apex
cd apex
pip install -v --disable-pip-version-check --no-cache-dir ./
!sh setup.sh
import re
import pandas as pd
from sklearn.utils import shuffle

data = pd.read_csv("/content/drive/MyDrive/
news.csv", encoding='utf8', index_col=0)

titles1 = data['Head']
print (titles1)

titles = titles1.dropna()
titles.convert_dtypes(convert_string=True)

```

```

texts1 = data['Text']
print (texts1)

texts = texts1.dropna()
texts.convert_dtypes(convert_string=True)

# создаем новый датафрейм
data2 = data[["Head", "Text"]]
# удаляем пропуски
data3 = data2.dropna(axis = 0, how = "any")
data4 = data3.astype('string')

titles1 = data['Head']
print (titles1)

titles = titles1.dropna()
titles.convert_dtypes(convert_string=True)

texts1 = data['Text']
print (texts1)

texts = texts1.dropna()
texts.convert_dtypes(convert_string=True)

# создаем новый датафрейм
data2 = data[["Head", "Text"]]
# удаляем пропуски
data3 = data2.dropna(axis = 0, how = "any")
data4 = data3.astype('string')

headlines = data4["Head"]
bodies = data4["Text"]
data5 = pd.concat([headlines, bodies])
data5 = shuffle(data5)

train = data5
valid = data5[:1000]
valid = shuffle(valid)

import numpy as np
import random
random.seed(1234)
np.random.seed(1234)

val_ind = random.sample(range(data5.shape[0]), 500)

with open("train.txt", "w") as file:
    file.write("\n".join(train))

```

```

with open("valid.txt", "w") as file:
    file.write("\n".join(valid))
!python3 pretrain_transformers.py \
    --output_dir=my_model \
    --model_type=gpt2 \
    --model_name_or_path=sberbank-ai/rugpt3small_based_on_gpt2 \
    --do_train \
    --train_data_file=train.txt \
    --do_eval \
    --fp16 \
    --eval_data_file=valid.txt \
    --per_gpu_train_batch_size 1 \
    --gradient_accumulation_steps 1 \
    --num_train_epochs 1 \
    --block_size 1024 \
    --overwrite_output_dir

```

Задача: сгенерировать заголовок новости, дообучив модель ruGPT-3, на основе датасета «riatomsk.csv»

Пример кода для генеративных моделей языка:

```

!pip3 install urllib3==1.26.4
!pip3 install transformers==2.8.0
!pip3 install wget

```

```
import wget
```

```

wget.download('https://raw.githubusercontent.com/sberbank-ai/ru-gpts/
master/generate_transformers.py', './')
wget.download('https://raw.githubusercontent.com/sberbank-ai/ru-gpts/
master/pretrain_transformers.py', './')

```

```
%%writefile setup.sh
```

```

git clone https://github.com/NVIDIA/apex
cd apex
pip install -v --disable-pip-version-check --no-cache-dir ./
!sh setup.sh

```

```

import re
import pandas as pd
from sklearn.utils import shuffle

```

```

data = pd.read_csv("/content/drive/MyDrive/
news.csv",encoding='utf8',index_col=0)

```

```

titles1 = data['Head']
print (titles1)

```

```

titles = titles1.dropna()
titles.convert_dtypes(convert_string=True)

```

```

texts1 = data['Text']
print (texts1)

texts = texts1.dropna()
texts.convert_dtypes(convert_string=True)

# создаем новый датафрейм
data2 = data[["Head", "Text"]]
# удаляем пропуски
data3 = data2.dropna(axis = 0, how = "any")
data4 = data3.astype('string')

l = pd.Series(data4['Text']).str.replace(r'^.*?\.', '', regex=True)
m = data4['Head']
data4 = pd.concat([m, l], axis=1)

headlines = data4["Head"]
bodies = data4["Text"]
data5 = pd.concat([headlines, bodies])
data5 = shuffle(data5)

train = data5
valid = data5[:1000]
valid = shuffle(valid)

import numpy as np
import random
random.seed(1234)
np.random.seed(1234)

val_ind = random.sample(range(data5.shape[0]), 500)

with open("train.txt", "w") as file:
    file.write("\n".join(train))
with open("valid.txt", "w") as file:
    file.write("\n".join(valid))

!python3 pretrain_transformers.py \
    --output_dir=my_model \
    --model_type=gpt2 \
    --model_name_or_path=sberbank-ai/rugpt3small_based_on_gpt2 \
    --do_train \
    --train_data_file=train.txt \
    --do_eval \
    --fp16 \
    --eval_data_file=valid.txt \
    --per_gpu_train_batch_size 1 \
    --gradient_accumulation_steps 1 \
    --num_train_epochs 1 \
    --block_size 1024 \

```

```
--overwrite_output_dir
```

Пример самостоятельной работы по преобразованию звучащей речи:

```
!git clone https://git.ffmpeg.org/ffmpeg.git ffmpeg
!pip install vosk
!pip install wget pydub wave tqdm
!apt-get ffmpeg

# Download Vosk model
!mkdir models
!wget -P models/ https://alphacephei.com/vosk/models/vosk-model-small-ru-0.22.zip
!unzip models/vosk-model-small-ru-0.22.zip -d models/ && rm models/vosk-model-small-ru-0.22.zip
!pip install pydub
from pydub import AudioSegment
import os

def mp3_to_wav(source, skip=0, excerpt=False):

    sound = AudioSegment.from_mp3(source) # load source
    sound = sound.set_channels(1) # mono
    sound = sound.set_frame_rate(16000) # 16000Hz

    if excerpt:
        excrept = sound[skip*1000:skip*1000+60000] # 30 seconds - Does not
work anymore when using skip
        output_path = os.path.splitext(source)[0]+"_excerpt.wav"
        excrept.export(output_path, format="wav")
    else:
        audio = sound[skip*1000:]
        output_path = os.path.splitext(source)[0]+".wav"
        audio.export(output_path, format="wav")

    return output_path
from google.colab import drive
drive.mount('/content/gdrive')
mp3_to_wav('/content/gdrive/MyDrive/example.mp3', 0, True)
from vosk import Model, KaldiRecognizer, SetLogLevel
from tqdm.notebook import tqdm
import wave
import os
import json

def transcript_file(input_file, model_path):

    # Check if file exists
    if not os.path.isfile(input_file):
```



```

        raise FileNotFoundError(os.path.basename(input_file) + " not
found")

    # Check if model path exists
    if not os.path.exists(model_path):
        raise FileNotFoundError(os.path.basename(model_path) + " not
found")

    # open audio file
    wf = wave.open(input_file, "rb")

    # check if wave file has the right properties
    if wf.getnchannels() != 1 or wf.getsampwidth() != 2 or
wf.getcomptype() != "NONE":
        raise TypeError("Audio file must be WAV format mono PCM.")

    # Initialize model
    model = Model(model_path)
    rec = KaldiRecognizer(model, wf.getframerate())

    # Get file size (to calculate progress bar)
    file_size = os.path.getsize(input_file)

    # Run transcription
    pbar = tqdm(total=file_size)

    # To store our results
    transcription = []

    while True:
        data = wf.readframes(4000) # use buffer of 4000
        pbar.update(len(data))
        if len(data) == 0:
            pbar.set_description("Transcription finished")
            break
        if rec.AcceptWaveform(data):
            # Convert json output to dict
            result_dict = json.loads(rec.Result())
            # Extract text values and append them to transcription list
            transcription.append(result_dict.get("text", ""))

    # Get final bits of audio and flush the pipeline
    final_result = json.loads(rec.FinalResult())
    transcription.append(final_result.get("text", ""))

    transcription_text = ' '.join(transcription)

    return transcription_text
transcription =
transcript_file('/content/gdrive/MyDrive/example_excerpt.wav',

```

```
'/content/models/vosk-model-small-ru-0.22')  
#/content/gdrive/MyDrive/example_excerpt.wav  
transcription
```

‘только двое какого возраста сын да не тринадцать лет и дочери яна семь лет хорошо где выросли вы сказали что достаточно переехали в этих котик васкес с чем связано с у меня просто мама закончила институт родила меня на этом курсовых закончил институт они по их поехали времени работа тире просто направлению раньше же выдавали жилье заканчивали она учитель языка и литературы закончила и выделенный жилье всего родители сейчас подражать господу а какое воздействие что такое деревне свою счастливое детство тем занимались дети нас мы сначала жили на одной улице’

### 13. Перечень рекомендованной литературы и ресурсов сети Интернет

#### а) основная литература:

– Janyan, I. Vankov, O. Tsaregorodtseva, A. Miklashevsky (2015) Remember down, look down, read up: Does a word modulate eye trajectory away from remembered location? Cognitive Processing, 16 (Suppl. 1), 259-263. DOI: 10.1007/s10339-015-0718-5

– Гришина Е. А., Савчук С. О. Корпус устных текстов в НКРЯ: состав и структура // Национальный корпус русского языка: 2006—2008. Новые результаты и перспективы. СПб.: Нестор-История, 2009, 129—149.

– Миклашевский А.А. Проект психолингвистической базы данных: взаимоотношение между модальностью и другими характеристиками русских существительных //Когнитивные исследования языка. М., Тамбов, СПб., 2015. Вып. XXII: Язык и сознание в междисциплинарной парадигме исследований: материалы Международного конгресса по когнитивной лингвистике. 30 сентября - 2 октября 2015 г. С. 550-551

– Бровко С.Л. PR-мероприятия: методика подготовки и проведения эффективных событий: методология PR-мероприятий: концепция петербургской школы PR. – СПб., 2012. – 187 с.

– Катлип С., Центер А., Брум Г. Паблик рилейшнз: Теория и практика. – М.: Вильямс, 2003. – 614 с.

– Кузнецов В.Ф. Связи с общественностью: Теория и технологии: Учебник для вузов. М.: Аспект Пресс, 2009. – 391 с.

– Резанова З.И., Некрасова Е.Д., Миклашевский А.А. Исследование психолингвистических и когнитивных аспектов языкового контактирования в проекте "языковое и этнокультурное разнообразие Южной Сибири в синхронии и диахронии: взаимодействие языков и культур//Русин. 2018. № 2 (52). С. 107-117.

– Сичинава Д. В. Обработка текстов с грамматической разметкой: инструкция разметчика // Национальный корпус русского языка: 2003-2005. Результаты и перспективы. — М., 2005, 136—154.

– Сичинава Д. В. Обработка текстов с грамматической разметкой: инструкция разметчика // Национальный корпус русского языка: 2003-2005. Результаты и перспективы. — М., 2005, 136—154.

#### б) дополнительная литература:

– Зубов А.В. Информационные технологии в лингвистике учебное пособие для студентов вузов, обучающихся по специальности 021800 – Теоретическая и прикладная лингвистика. - М.: Академия, 2004. – 205 с.

– Мишанкина Н.А. Базы данных в лингвистических исследованиях. Вопросы лексикографии, Выпуск № 1 (3), 2013 – С.25-33.

– Поляков А. Е. Технология подготовки информации в Национальном корпусе русского языка // Национальный корпус русского языка: 2003-2005. Результаты и перспективы. — М., 2005, 175—192.

- Потапова Р.К. Новые информационные технологии и лингвистика. – М.: Ленанд, 2016. – 364 с.
- Хроленко А.Т., Денисов А.В. Современные информационные технологии для гуманитария: практическое руководство. – 3-е изд. – М.: Флинта: Наука, 2010. - 127, с.
- Информатика для гуманитариев: Учебник и практикум / Кедрова Г.Е. - Отв. ред. М.: Юрайт, 2016. 439 с.
- в) ресурсы сети Интернет:
  - открытые онлайн-курсы
  - репозиторий github.com

#### **14. Перечень информационных технологий**

- а) лицензионное и свободно распространяемое программное обеспечение:
  - Microsoft Office Standart 2013 Russian: пакет программ. Включает приложения: MS Office Word, MS Office Excel, MS Office PowerPoint, MS Office On-eNote, MS Office Publisher, MS Outlook, MS Office Web Apps (Word Excel MS PowerPoint Outlook);
  - E-prime v2.0 или v3.0
  - публично доступные облачные технологии (Google Docs, Яндекс диск и т.п.).
- б) информационные справочные системы:
  - Электронный каталог Научной библиотеки ТГУ – <http://chamo.lib.tsu.ru/search/query?locale=ru&theme=system>
  - Электронная библиотека (репозиторий) ТГУ – <http://vital.lib.tsu.ru/vital/access/manager/Index>
  - ЭБС Лань – <http://e.lanbook.com/>
  - ЭБС Консультант студента – <http://www.studentlibrary.ru/>
  - Образовательная платформа Юрайт – <https://urait.ru/>
  - ЭБС ZNANIUM.com – <https://znanium.com/>
  - ЭБС IPRbooks – <http://www.iprbookshop.ru/>
- в) профессиональные базы данных (*при наличии*):
  - База данных RuWordPerception (ТГУ) – <http://clingv.ru:3839/>

#### **15. Материально-техническая база проведения практики**

- Аудитории для проведения занятий лекционного типа.
- Аудитории для проведения экспериментальной части практики.
- Аудитории для проведения занятий семинарского типа, индивидуальных и групповых консультаций, текущего контроля и промежуточной аттестации.
- Помещения для самостоятельной работы, оснащенные компьютерной техникой и доступом к сети Интернет, в электронную информационно-образовательную среду и к информационным справочным системам.
- Материально-техническая база профильной организации, включая перечень помещений, предоставленных профильной организацией в соответствии с приложением 2 к договору о практической подготовке обучающихся.

#### **16. Информация о разработчиках**

- Степаненко Андрей Александрович, Томский государственный университет, старший преподаватель кафедры общей, компьютерной и когнитивной лингвистики.