

Московский Авиационный Институт  
(Национальный исследовательский институт)



**«Информатика: проблемы, методы, технологии» (IPMT-2021)**

**КЛАССИФИКАЦИЯ СУЩЕСТВИТЕЛЬНЫХ  
ИЗ ТЕКСТОВ МЕТОДАМИ МАШИННОГО  
ОБУЧЕНИЯ НА ОСНОВЕ ПРИЗНАКОВ  
КОНТЕКСТУАЛЬНОЙ СИНОНИМИИ**

магистрант, каф. 319 Милованова Е.Е.

# Естественный язык

Естественный язык – это язык, используемый для общения людей и не созданный целенаправленно.

- Обладает большим количеством семантических взаимосвязей;
- Позволяет описать объекты разными словесными конструкциями;
- Часто основывается не на точном значении единицы текста, а на её эмоциональной и стилистической окраске.



# Проблема многозначности слов

- ❖ **Естественный язык** – сложная система, изначально не отличающаяся однозначностью толкования.
- ❖ **Неоднозначность** проявляется на всех уровнях анализа языка, что затрудняет автоматизированный анализ текстов.
- ❖ **Значение единицы языка** часто зависит от контекста употребления, слова в различных контекстах могут приобретать различные значения.
- ❖ **Выразительные средства**, использование синонимов, антонимов и т.д. для уточнения или усиления смысла ещё более усложняют автоматический анализ текста.

# Контекстные синонимы

**Синонимы** – слова, равнозначные или похожие по значению.

**Контекстный или контекстуальный синоним** – это слово, которое равнозначно другому слову лишь в определенной ситуации, в конкретном контексте.

**Контекст** – это относительно законченная по смыслу часть текста или высказывания.

**Синоним  $\neq$  Контекстный синоним**

# Пример работы существующих программных средств по выделению контекстных синонимов

Исходное предложение	Онлайн – синонимайзер	Синонимайзер текстов
Вдруг он поднял голову, глаза его засверкали, он топнул ногою, оттолкнул секретаря с такою силою, что тот упал, и, схватив чернильницу, пустил ею в заседателя. Все пришли в ужас.	<b>Внезапно</b> он поднял голову, <b>очи</b> его засверкали, он топнул ногою, оттолкнул секретаря с такою силою, <b>собственно что что свалился</b> , и, схватив чернильницу, пустил ею в заседателя. Все <b>приехали</b> в кошмар.	<b>Внезапно</b> он поднял <b>сразу темя</b> , глаза его засверкали, он топнул ногою, оттолкнул секретаря с такою силою, что тот <b>свалился</b> , и, схватив чернильницу, пустил ею в заседателя. Все пришли в <b>страх</b> .

# Проблемы проектирования программных средств для выделения контекстуальных синонимов

- ❖ Зависимость от **объёмов исходных данных**. Как следствие, необходимость наличия и обработки больших и сверхбольших размеченных корпусов текстов, онтологий и тезаурусов;
- ❖ Проблема **подбора метрики** оценки корректности используемых эмпирических критериев, так как она зависит от результатов, представляемых человеком-экспертом и/или программного средства.

# Признаки контекстуальных синонимов

- ❖ Полное или частичное совпадение характеристик, присущих словам-синонимам. То есть, контекстные синонимы должны совпадать по части речи, роду, числу, одушевлённости и т.д. Допустимы отклонения, например, для именованных сущностей или устойчивых выражений.
- ❖ Семантическая взаимозаменяемость с описываемым понятием в заданном контексте.
- ❖ Тождественность (не обязательно полная) толкования смысла слова с описываемым понятием.
- ❖ Принадлежность к одной предметной области.
- ❖ Стилистическое соответствие слова контексту.
- ❖ Поведенческая схожесть для соблюдения правильности построения предложения.

# Описание классов сущностей в тексте

- ❖ **Person** – одушевлённый персонаж, выполняющий активную роль в повествовании.
- ❖ **Object** – неодушевлённый предмет, имеющий важную роль в тексте или над которым производятся какие-либо действия.
- ❖ **Something** – объекты или одушевлённые лица, не играющие важной роли в тексте.

# Средства разработки

- ❖ Язык разработки *Java*;
- ❖ Фреймворк *TAWT* – библиотека для языка *Java*, реализующая графематический, морфологический и семантико-синтаксические анализы текста на русском языке.
- ❖ *Weka* (Waikato Environment for Knowledge Analysis) — свободное программное обеспечение для анализа данных и машинного обучения, написанное на *Java* в Университете Уаикато (Новая Зеландия), распространяющееся по лицензии GNU GPL.
- ❖ *Spring Framework* – универсальный фреймворк с открытым исходным кодом для *Java*-платформы.
- ❖ Среда разработки: *IntelliJ IDEA*.

TAWT



# Вектор признаков

- ❖ именованность;
- ❖ род;
- ❖ одушевленность;
- ❖ общая частота употребления;
- ❖ количество раз, когда слово было главным в предложении;
- ❖ общее количество зависимых от слова глаголов;
- ❖ общее количество раз, когда слово зависимо от глагола;
- ❖ общее количество зависимых от слова прилагательных;
- ❖ общее количество раз, когда слово зависимо от прилагательного;
- ❖ общее количество зависимых от слова существительных;
- ❖ общее количество раз, когда слово зависимо от существительного.

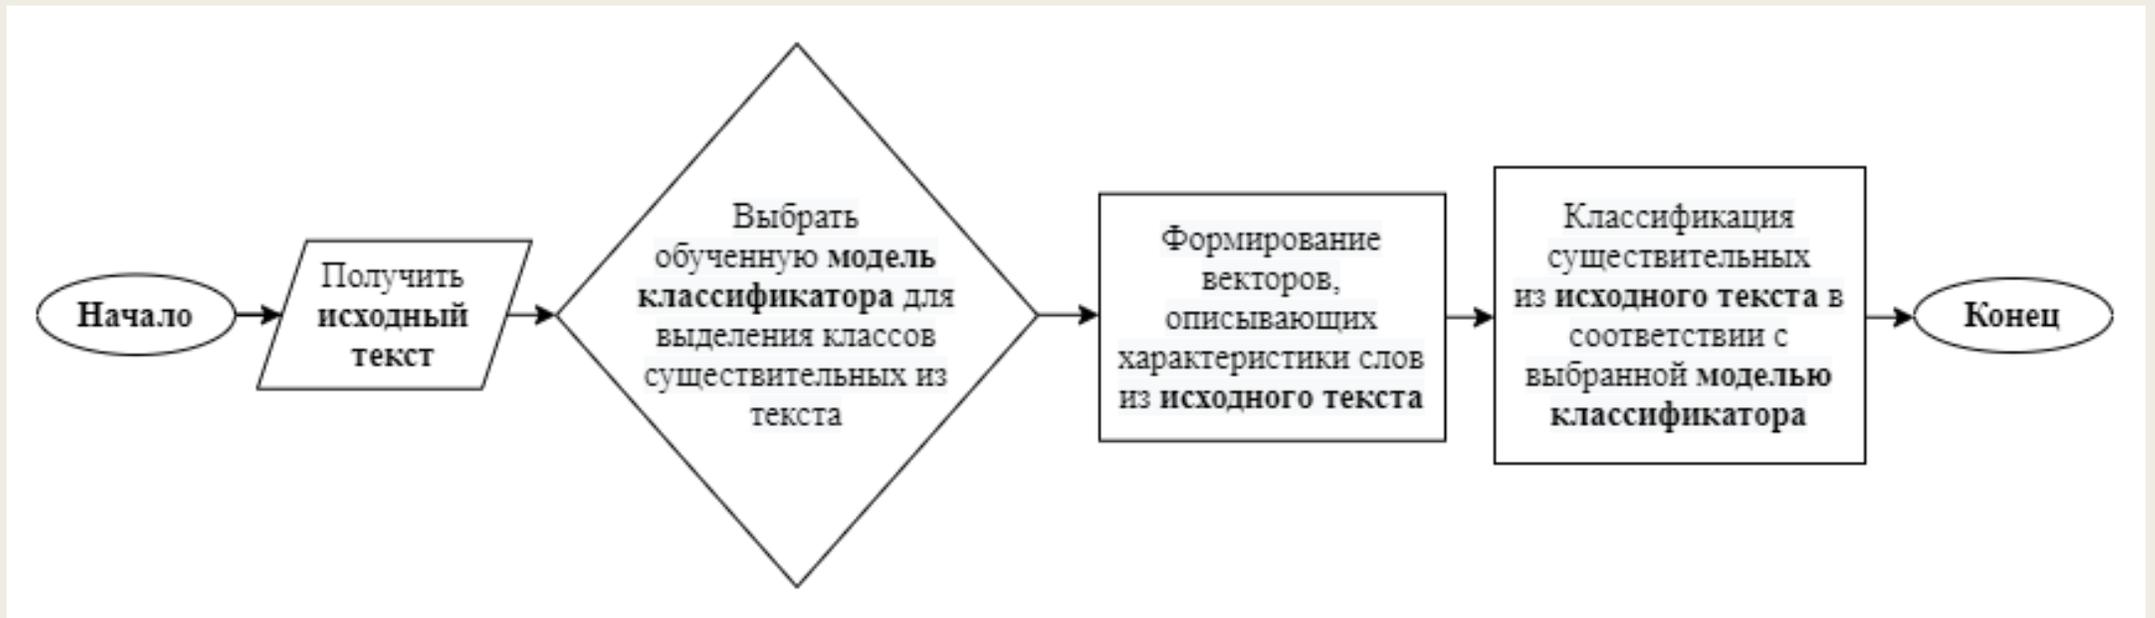
# Алгоритм векторизации существительных из текстов на естественном языке



# Описание используемых для обучения классификатора текстов

Автор	Название произведения	Количество существительных в тексте	Общее количество слов в тексте
Н.Н. Носов	«Живая шляпа»	34	187
Л.А. Чарская	«Лидианка»	391	1201
Л.А. Чарская	«Поповна»	505	1603
Л.А. Чарская	«Нелюбимая»	559	1692
А.П. Чехов	«Каштанка»	519	1914

# Алгоритм классификации существительных из текстов на естественном языке



# Оценка точности работы моделей классификатора на основе текстов художественной литературы (класс «person»)

А.С. Пушкин «Капитанская дочка», глава 9



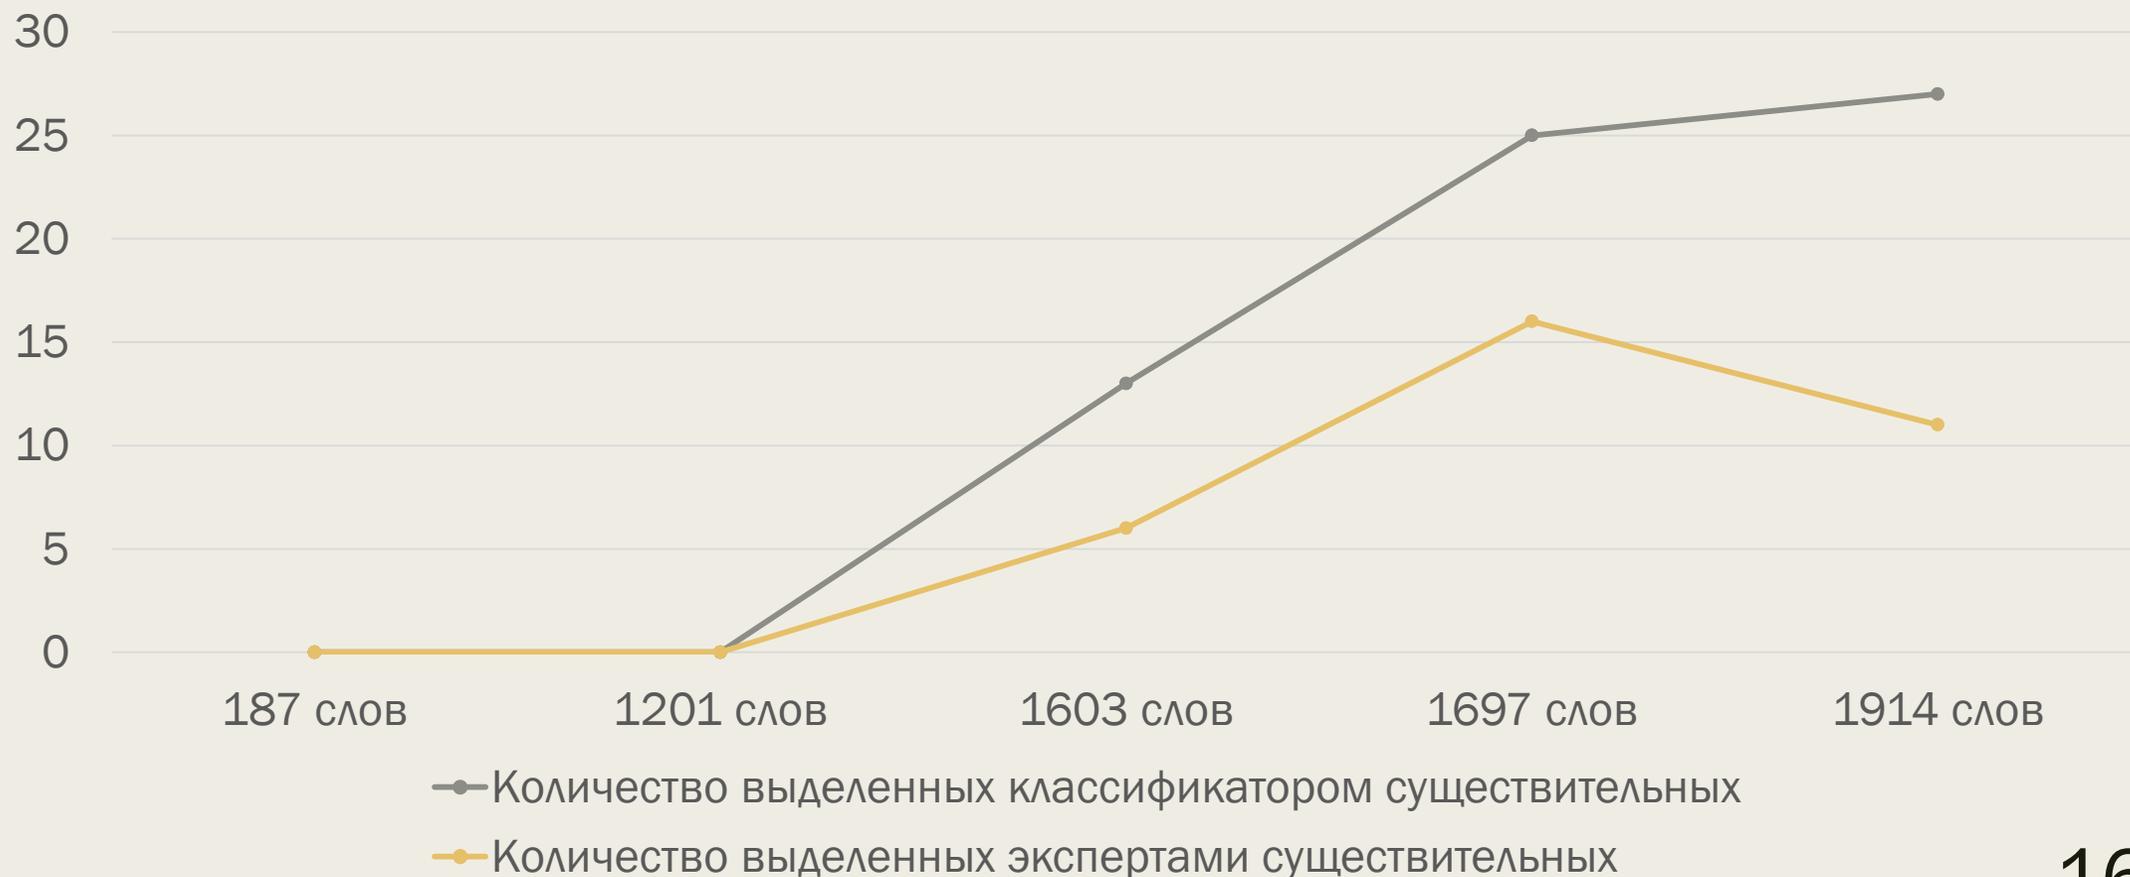
# Оценка точности работы моделей классификатора на основе текстов художественной литературы (класс «object»)

А.С. Пушкин «Капитанская дочка», глава 9



# Оценка точности работы моделей классификатора на основе текстов художественной литературы (класс «person»)

А.П. Чехов «Заблудшие»



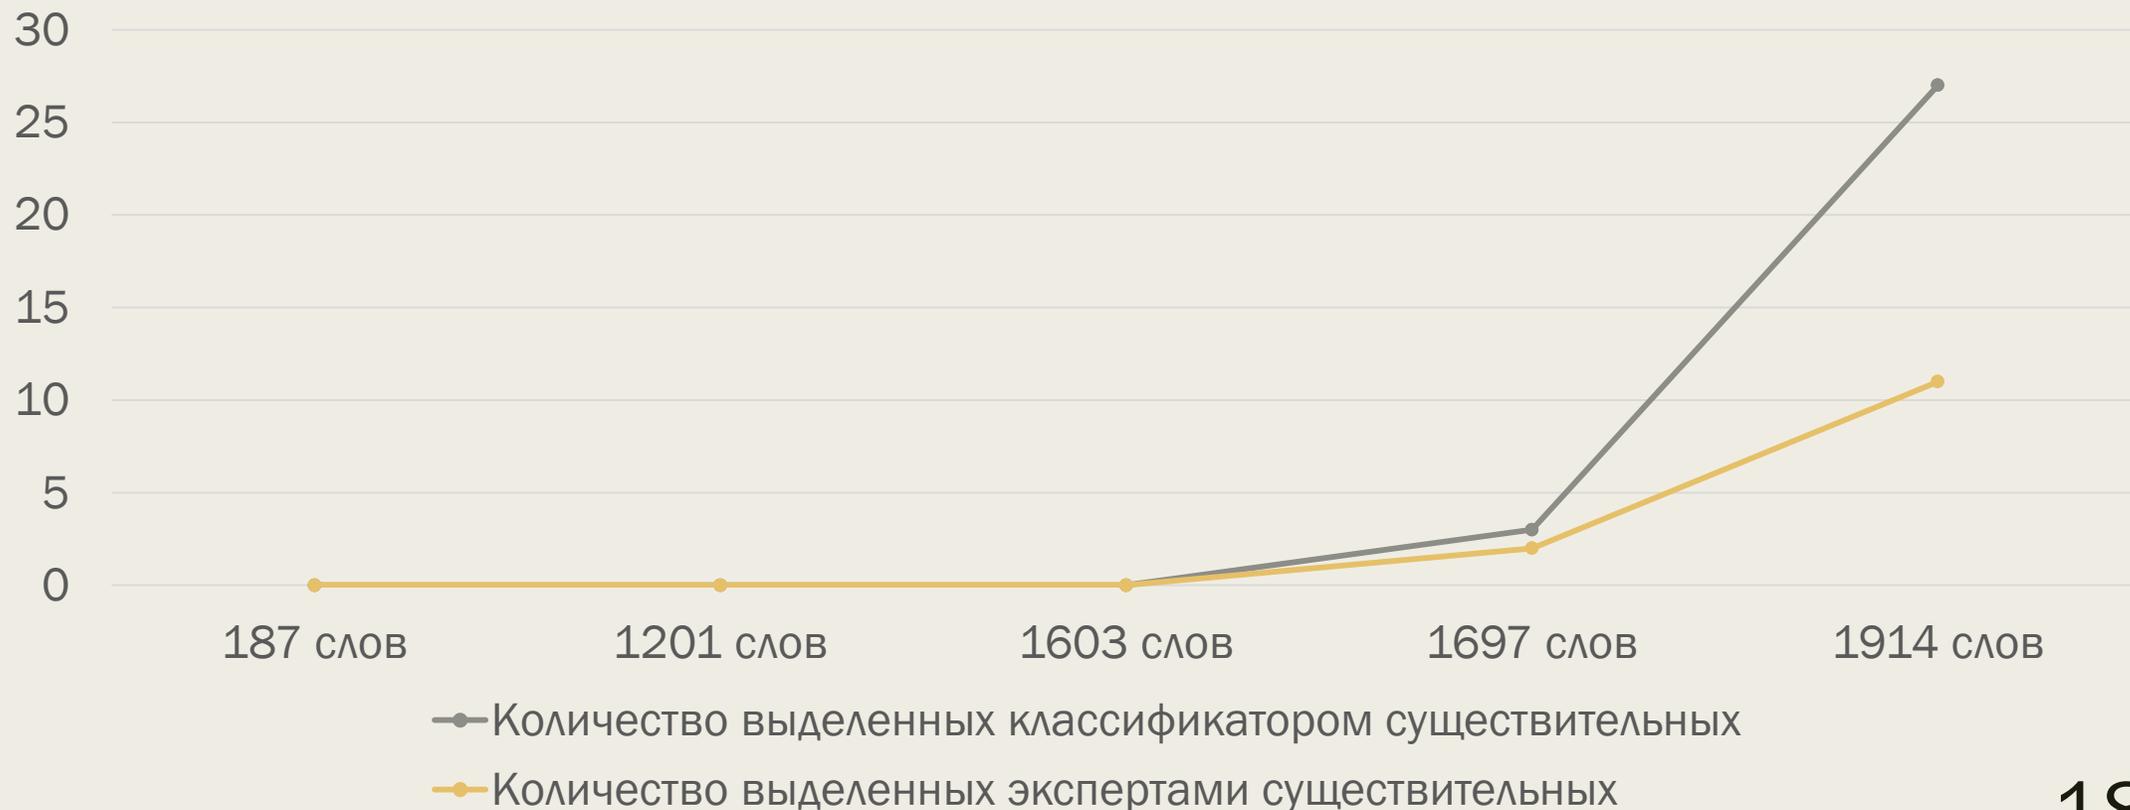
# Оценка точности работы моделей классификатора на основе текстов художественной литературы (класс «object»)

А.П. Чехов «Заблудшие»



# Оценка точности работы моделей классификатора на основе текстов художественной литературы (класс «person»)

Новостная статья «В поисках жизни во Вселенной хотят использовать теорию игр»



# Оценка точности работы моделей классификатора на основе текстов художественной литературы (класс «object»)

Новостная статья «В поисках жизни во Вселенной хотят использовать теорию игр»



# Пути развития

- ❖ Расширение библиотеки обученных моделей классификации на текстах разных жанров.
- ❖ Проведение дополнительного лингвистического анализа для совершенствования списка признаков для векторизации.
- ❖ Развитие используемых методов векторизации текстов.
- ❖ Создание ансамбля из обученных моделей классификации для качественного улучшения результатов.

# Выводы

1. Сформирован **список характеристик**, включающий в себя морфологические и синтаксические признаки, которые могут быть использованы для формирования наборов данных для обучения классификатора.
2. Предложен **алгоритм векторизации** слов на основе признаков контекстуальной синонимии для формирования набора данных, предназначенных для обучения классификатора.
3. Проведено исследование **точности** результатов работы моделей классификатора, обученных на текстах художественной литературы.
4. Отмечена **зависимость** результатов классификации от размеров текстов, являющихся основой для обучения классификатора, и текстов, для которых выполняется процедура классификации существительных.
5. Выявлено, что для **повышения качества** выделения разных классов требуется использование моделей, обученных на разных текстах.



# Спасибо за внимание!

«Классификация существительных из текстов методами машинного обучения на основе признаков контекстуальной синонимии»

магистрант, каф. 319 **Милованова Е.Е.**