Ефименко И.В.
Irina.Efimenko@avicomp.ru

Ontos
NOW YOU KNOW

ОБРАБОТКА ЕСТЕСТВЕННОЯЗЫКОВЫХ ТЕКСТОВ: ОНТОЛОГИЧНОСТЬ В ЛИНГВИСТИКЕ И ДИСКУРСИВНОСТЬ В ИЗВЛЕЧЕНИИ ЗНАНИЙ

План презентации

Ontos
NOW YOU KNOW

- **Введение**
- **Свойства дискурса**
- **Понятие контактности**
  и Shallow-**подход**
- **Разграничение релевантных и нерелевантных данных,**
  разрешение конфликтов
- **Онтологии:**
  интерпретация лингвистических данных
- **Заключение**

Введение

Ontos
NOW YOU KNOW

- Онтология как фильтр
- Shallow-подход и дискурс, имитация синтаксического анализа
- Лексические vs.предметные онтологии, обращение к экстралингвистическим данным
- Дискурсивный подход vs. анализ отдельных фрагментов

Введение

Ontos
NOW YOU KNOW

- Принципы работы многоязыковых систем семейства OntosMiner:
  - Анализ под управлением онтологий
  - Модифицированный Shallow-подход. Принцип «контактности» (закономерности развертывания дискурса)
  - Использование онтологических знаний
    - на этапе формирования модели
    - при интерпретации лингвистических явлений (в частности, разрешении неоднозначности, проявляющейся на различных уровнях автоматической обработки).
  - Дискурс и онтология: разрешение кореференции и анафоры
  - Понятие «аннотации» как служебного и/или семантического ярлыка. *«Технологические приемы».*

Дискурс:
Линейность

Ontos
NOW YOU KNOW

- Непрерывность, связность, смысловое единство дискурса
- «Связность» онтологии, интерпретация изолированных объектов

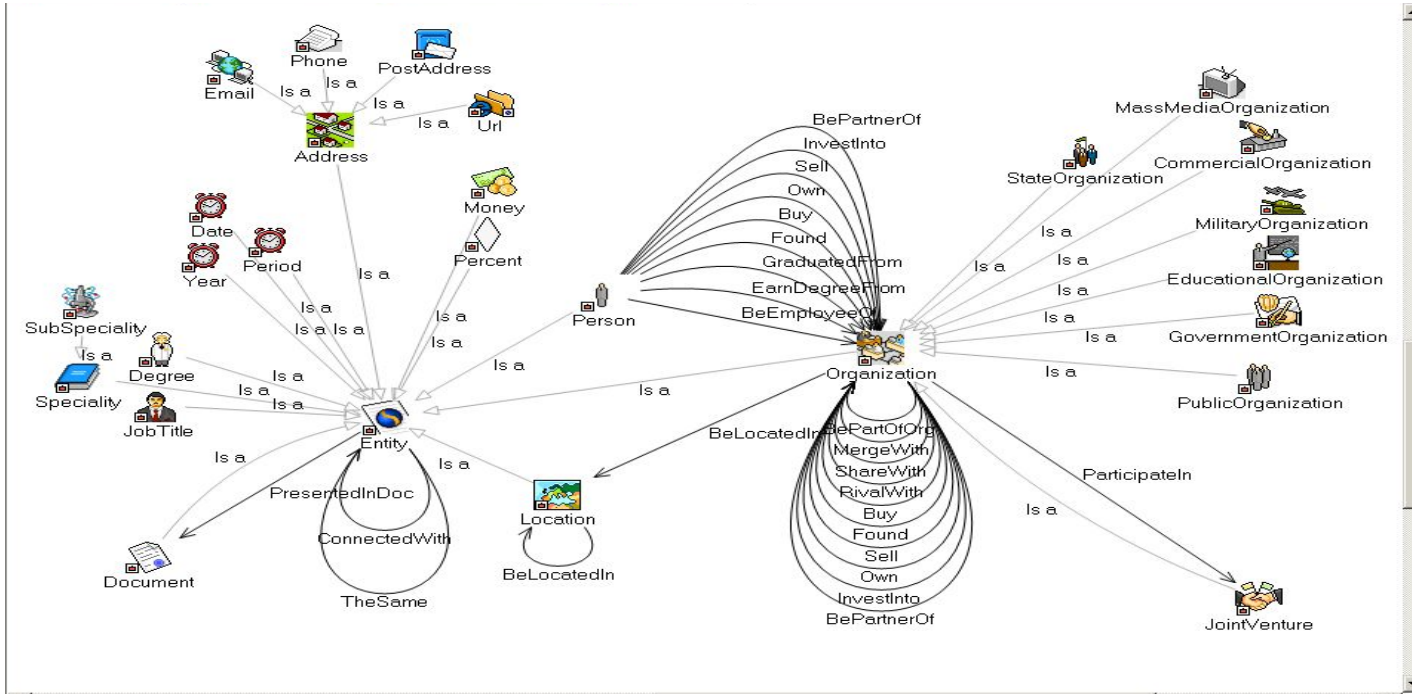

Понятие контактности и Shallow-подход: «Типология ошибок»

Ontos
NOW YOU KNOW

- **Нарушение целостности шаблона**, *«**ошибка первого рода**»*
  - Пример 1: *Синицына (в девичестве Орлова) Анна-Мария Гузермес, выпускница Одесского сельскохозяйственного техникума и участник конференции «Сделаем «Красную Книгу» белой», является менеджером картеля «Лига Охраны Перелетных Птиц».*
    - Аннотации объектов: Синицына (в девичестве Орлова) Анна-Мария Гузермес (тип: Лицо); Одесского сельскохозяйственного техникума (тип: Организация); *возможно*, конференции «Сделаем «Красную Книгу» белой» (тип: Организация), менеджером (тип: Должность) и картеля «Лига Охраны Перелетных Птиц» (тип: Организация).

Понятие контактности и Shallow-подход: «Типология ошибок»

Ontos
NOW YOU KNOW

- Пример 1: *Синицына (в девичестве Орлова) Анна-Мария Гузермес, выпускница Одесского сельскохозяйственного техникума и участник конференции «Сделаем «Красную Книгу» белой», является менеджером картеля «Лига Охраны Перелетных Птиц».*

  - Входные аннотации на последующих этапах обработки (идентификация связей): Лицо, Организация, Должность и служебная аннотация, маркирующая онтологический предикат (в данном случае, глагол «являться» в определенной форме).
  - Схема шаблона: {Лицо (в соответствующей грамматической форме)}, {"являться" в 3 л. ед.ч.}, {Должность (в соответствующей грамматической форме)}, {Организация (в соответствующей грамматической форме)}.

Понятие контактности и Shallow-подход: «Типология ошибок»

Ontos
NOW YOU KNOW

- **Ошибочная интерпретация шаблона**,
  *«**ошибка второго рода**»*

  - Пример 2: *Лю Чю Хе Сянь Вань является автором модуля, который много лет успешно работает в системе «Биг Пис» (из предыдущего контекста при этом следует, что «Биг Пис» - название компании).*

    - Шаблон: {Лицо (в соответствующей грамматической форме)}, {"работать" в 3 л. ед. ч.}, {Организация (в соответствующей грамматической форм, с предлогом)}
    - Интерпретация: «Лю Чю Хе Сянь Вань много лет успешно работает в системе «Биг Пис»

Наличие ограничений на семантику актантов не является решением

Разграничение релевантных и нерелевантных данных:
фокус внимания

Ontos
NOW YOU KNOW

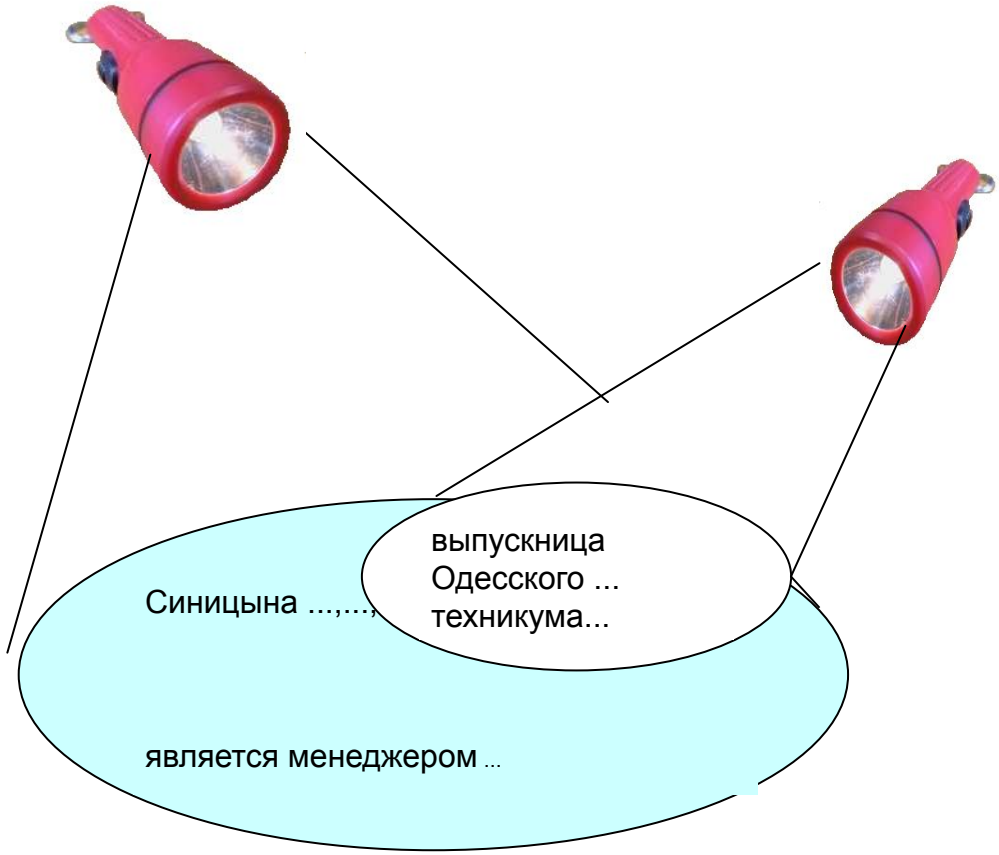

Методы разрешения конфликтов:

Пример списка с атрибутами *(фрагмент реального текста)*

Ontos
NOW YOU KNOW

Установлены члены международного синдиката «Золотой мак»:

- **Мгерабишвили Зураб Вахтангович**, 1943 **г.р., ур. и житель г. Поти, Грузия, лидер синдиката, женат на Мгерабишвили А. К.**
- **Могулиев Абдулхайр Магомедович**, 17 **марта** 1984 **года рождения, уроженец Согдийской области Таджикистана, житель кишлака Одурван.**
- **Чон Ду Хван, гражданин Кореи**, 1939 **г.р., курьер, брат гражданина Кореи Ли Ю Тинь, верховного жреца «Группы раскаявшихся флибустьеров Капитана Флинта»**
- **Братья Кукушкины – Сергей Анатольевич**, 1978 **г.р., и Петр Анатольевич**, 1980 **г.р., уроженцы Белгородской области, проживают: Республика Северная Осетия-Алания, г.Ардон, ул. Желездодорожная, д.**5 **кв.** 1. **Оба числятся грузчиками в ООО «Ближний свет» (Республика Северная Осетия-Алания, г.Ардон, ул. Желездодорожная, д.**5)
- **Ли Си Цин, гр. КНР, постоянно проживает в Ташкенте, Узбекистан, хозяин городского рынка «Бешкеш»**
- **Абдуллаев Кодир Исмоилович**, 15.10.66 **г.р., ур. г. Андижан, Узбекистан, проживает в Узбекистане: г.Корасув, ул.Навруз д.** 28, **кв.** 2, **безработный, его женою является известная Ибрагимова Насибахон Шухратовна**, 9 **марта** 1980 **г.р., уроженка и жительница г.Корасув, ул.Навруз д.** 28, **кв.** 2, **медсестра городской больницы №** 4

Методы разрешения конфликтов:
Пример списка с атрибутами

Ontos
NOW YOU KNOW

- *Необходимо установить связь типа «являться сотрудником, работать» между Организацией и каждым из лиц, являющимися вершинами элементов списка.*
- *Недопустимо появление связи типа «являться сотрудником, работать» между Организацией и другими лицами, фигурирующими в тексте, но при этом не являющимися вершинами элементов списка.*
- *Дополнительные маркеры вершин списка могут отсутствовать.*

Методы разрешения конфликтов :

Использование имен и атрибутов аннотаций

Ontos
NOW YOU KNOW

- *Приписывание атрибутов*
  - **Организация** (**Лицо**.attr == “1”, (**Лицо**)*)+
- *Переименование аннотаций*
  - **Организация** (**Лицо**1)+
- *«Захват» нерелевантных фрагментов*
  - **Организация** (**Элемент списка**)+
- *Включение во входные данные «лишних» аннотаций*
  - Input: ***C****omma…*

Методы разрешения конфликтов :

Интерпретация списочных структур

Ontos
NOW YOU KNOW

- **Гвинджи Фануэл Таванда** (Gvindgy Fanuel Tavanda);
- **Горезваримва Портия** (Goredfrimva Portiya);
- **Мпоко Луринда**; **Нтандо Анние Дзиямо Тадуру**, 1981 **г.р.**
- **Такавира-Куун Клаудиус**;
- **Сбанда Тобекиле** (Sibanda Tobekili), 22.05.1982 **г.р.**

Онтологии:

интерпретация лингвистических данных

Ontos
NOW YOU KNOW

- 1. **Восстановление имплицитной информации**
  - **А) Восстановление эллипсисов.**
    - *«До IBM, г-н X работал Microsoft»* (две связи одного типа - "работать, быть сотрудником" - с одним общим актантом)
  - **Б) Восстановление ситуаций за рамками текста.**
    - *«В этом году г-н X стал главным редактором газеты "Известия"»*
    - *«В этом году г-н X стал программистом Oracle»*

Онтологии:

интерпретация лингвистических данных

Ontos
NOW YOU KNOW

- 2. **Интерпретация типа временной сущности**
  - *Задача взаимного расположения на оси времени извлекаемых событий*
  - *Динамическое изменение интерпретации элементов шкалы в рамках дискурса*
    - «Иванов был уволен из МВД в 1985 году» -> «Иванов работал в МВД до 1985 года»

Заключение

Ontos
NOW YOU KNOW

- **Целесообразность автоматической обработки естественноязыковых текстов *под управлением предметных онтологий* в констексте восприятия входного текста как *целостного дискурса***
- **Необходимость использования *экстралингвистической информации* при *интерпретации лингвистических данных***
- **Совмещение двух концепций, являющихся в настоящее время наиболее актуальными в смежных, с точки зрения ЕЯ-систем, дисциплинах: *онтологически-ориентированных методов* в области ИИ и информационных технологий и *дискурсивного анализа* в лингвистике**
  - **Новый класс подходов к автоматической обработке естественного языка**

Ontos
NOW YOU KNOW

Спасибо
за внимание!