

---

# ИСИДА-Т

---

Интеллектуальная система  
извлечения и анализа данных из  
текстов

---

# Извлечение информации

## **Цель:**

- извлечь значимую информацию определенного типа из (больших массивов) текста для дальнейшей аналитической обработки

## **Результат:**

- структурированные данные (объекты+отношения)
-

# Примеры предметных областей

- **Спортивные события:** *<победитель>*, *<проигравший>*, *<счет>*, *<место встречи>*, *<дата>...*
- **База данных о рынке жилья:** *<район>*, *<цена>*, *<количество комнат>*, *<контактный телефон>...*
- **Выпуск новых товаров:** *<производитель>*, *<дата выпуска>*, *<название товара> ...*

---

# Приложения технологии извлечения информации

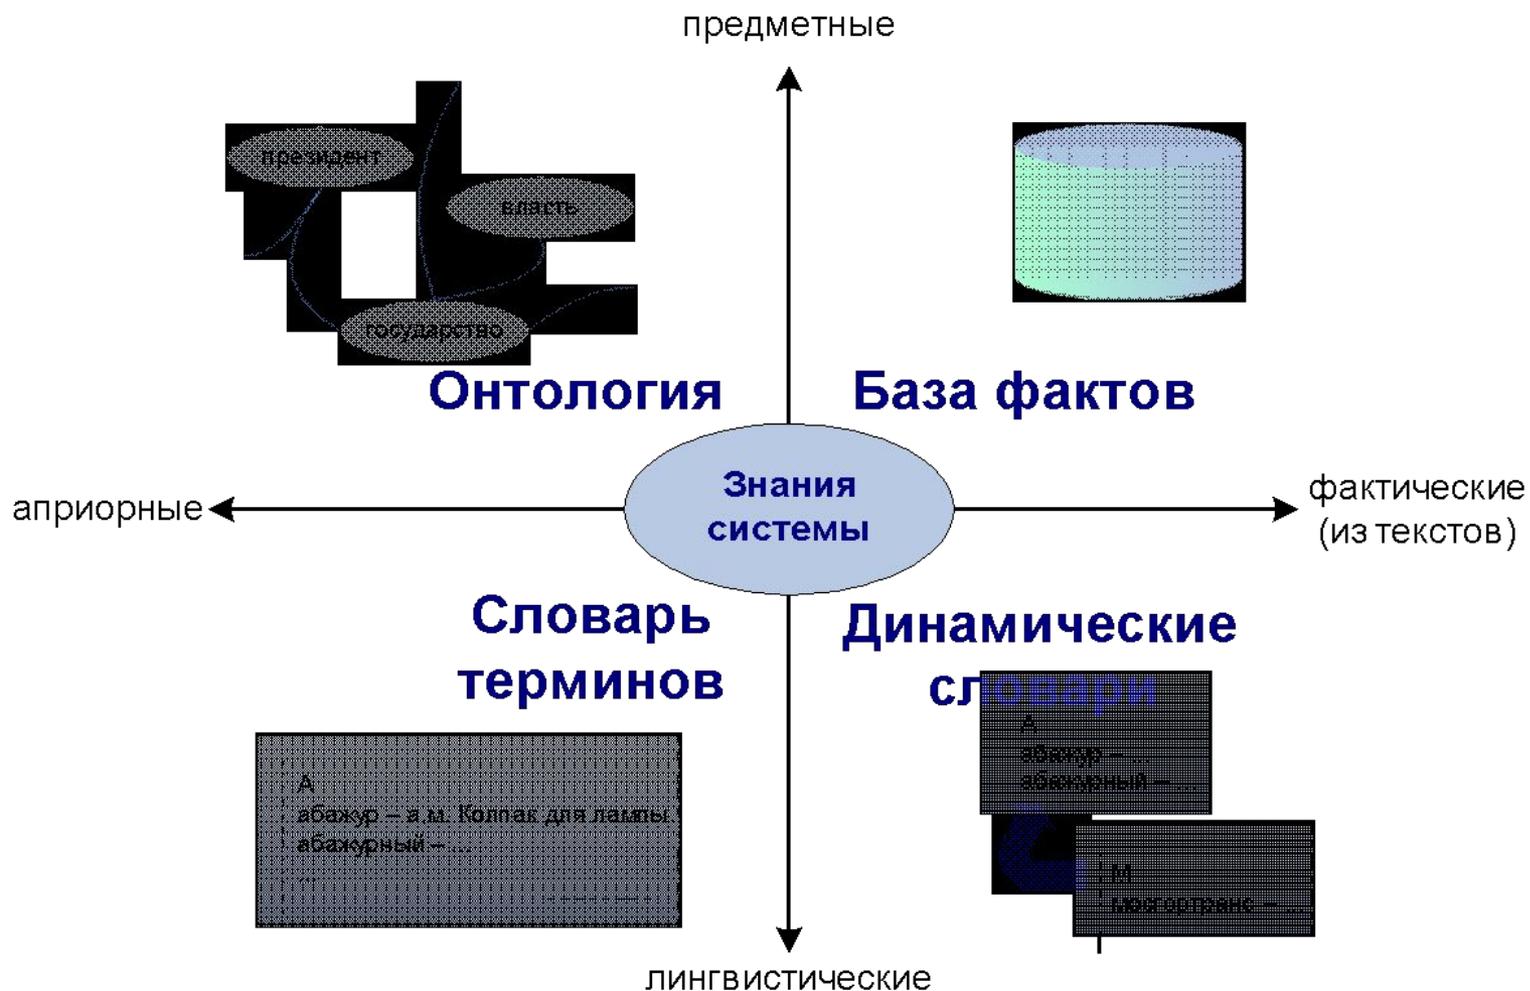
- семантическая кластеризация и классификация
  - автоматическое аннотирование
  - визуализация данных
  - семантическое сравнение и поиск
  - создание баз данных
  - ...
-

---

# Основные компоненты системы

- Инфраструктурные службы  
(конфигурирование, параллельная обработка, взаимодействие модулей)
  - Лингвистический процессор
  - Интерпретатор правил извлечения информации
  - Модули работы со знаниями предметной области
-

# Знания в системе



---

# Извлечение информации

- **В «слабом» смысле**

- Обнаружение и пометка текстовых элементов и отношений (разметка текста)

- **В «сильном» смысле**

- Переход от текстовых структур к модели предметной области
-

---

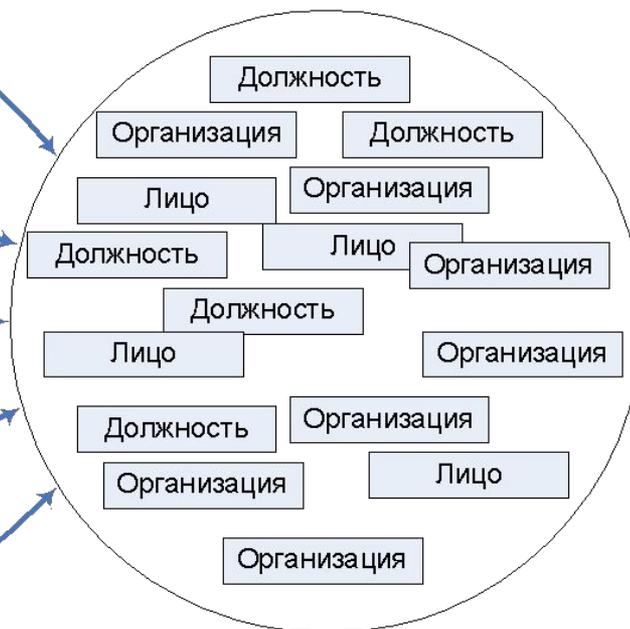
# Извлечение информации в «слабом» СМЫСЛЕ

- Лингвистическая обработка
    - Токенизация
    - Разбиение на предложения
    - Морфология
    - Частичный синтаксический анализ
  - Словарное распознавание
  - Распознавание именованных сущностей
  - Частичный семантический анализ (в том числе, с использованием контекстных правил)
-

# Построение первичных текстовых объектов

## Правила построения текстовых объектов

- Ковальчук Михаил Федорович* родился 5 января 1948 г. в Черниговской области Украинской ССР.[...] Прошел путь от транспортного рабочего, водителя до генерального директора одного из крупнейших автотранспортных предприятий Санкт-Петербурга - АОЗТ "Трансэк". Возглавляет предприятие с 1978 года. [...] Женат, имеет двоих сыновей.
- Об этом "ДП" сообщил генеральный директор ЗАО "Трансэк" Михаил Ковальчук. //31 июля 2003
- [...] - говорит исполнительный директор транспортной компании ЗАО «Трансэк» Игорь Ковальчук. //06.10.04
- Вчера член-корреспондент РАН Михаил Ковальчук был назначен на должность директора Российского научного центра "Курчатовский институт". //04.02.05
- [...] по словам генерального директора транспортной компании "Трансэк" Игоря Ковальчука, пробок не наблюдается. // 24 апреля 2006 г.



# Примеры текстовых объектов

<b>Тип:</b>	<b>@лицо</b>		
<b>Подтип:</b>	—		
<b>Атрибут</b>	<b>Значение</b>	<b>Текстовый элемент</b>	
Фамилия		<i>Ковальчук</i>	
Имя		<i>Михаил</i>	
Отчество		<i>Федорович</i>	

<b>Тип:</b>	<b>@организация</b>		
<b>Подтип:</b>	?		
<b>Атрибут</b>	<b>Значение</b>	<b>Текстовый элемент</b>	
Название		<i>Трансэк</i>	
Правовая форма	AV@зао	<i>АОЗТ</i>	

<b>Тип:</b>	<b>@организация</b>		
<b>Подтип:</b>	<b>@транспортная_компания</b>		
<b>Атрибут</b>	<b>Значение</b>	<b>Текстовый элемент</b>	
Название		<i>Трансэк</i>	
Правовая форма	AV@зао	<i>ЗАО</i>	

<b>Тип:</b>	<b>@лицо</b>		
<b>Подтип:</b>	—		
<b>Атрибут</b>	<b>Значение</b>	<b>Текстовый элемент</b>	
Фамилия		<i>Ковальчук</i>	
Имя		<i>Михаил</i>	

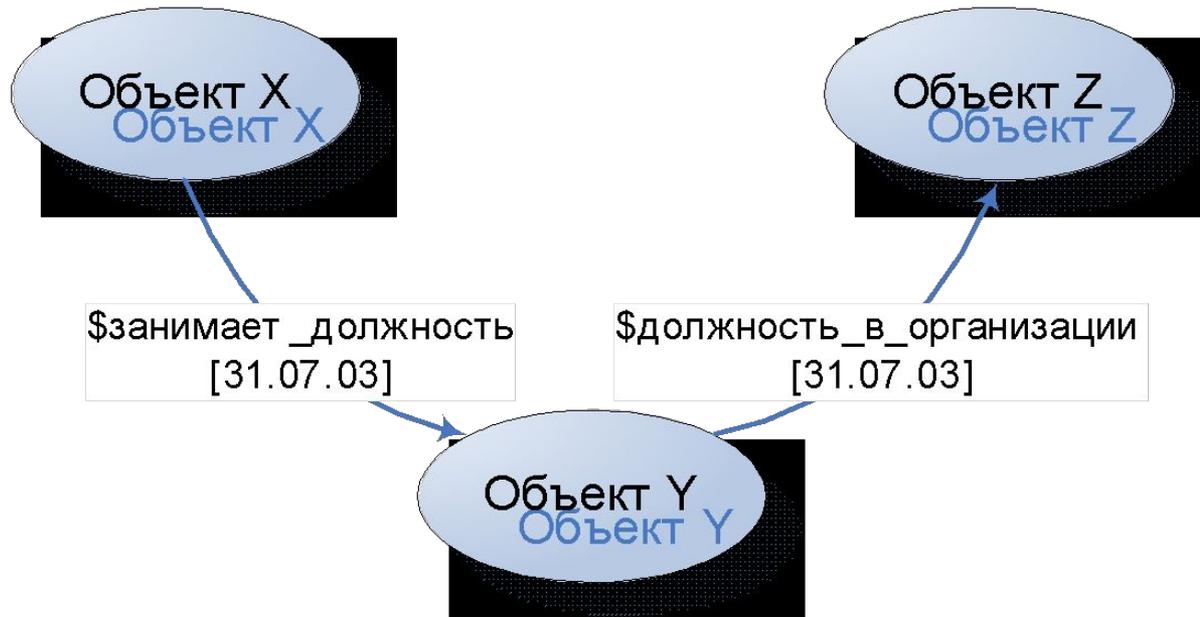
<b>Тип:</b>	<b>@должность</b>		
<b>Подтип:</b>	<b>@генеральный_директор</b>		

			...
--	--	--	-----

Всего по приведенным фрагментам построено 19 таких объектов. Очевидно, что число **реальных объектов**, упомянутых в текстах, меньше. Системе предстоит установить, какие из **текстовых объектов** соответствуют одному и тому же **реальному объекту**.

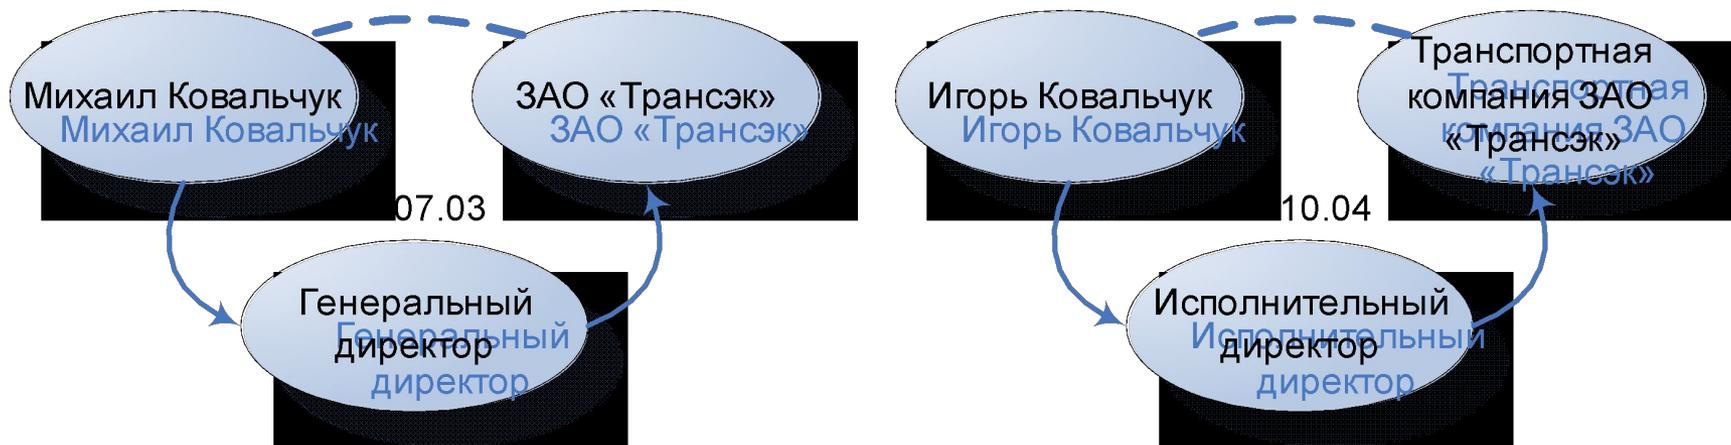
# Построение текстовых фактов

- Текстовый факт — ситуация заданной структуры, имеющая временн'ую координату



(`$занимает_должность` (Объект X, Объект Y), время: 31.07.03) &  
(`$должность_в_организации` (Объект Y, Объект Z), время: 31.07.03)

# Построение текстовых фактов



## Примеры построенных фактов

- Михаил Ковальчук — генеральный директор ЗАО "Трансэк" [ 31.07.03]
- Михаил Ковальчук — член-корреспондент РАН, директор Российского научного центра "Курчатовский институт" [ 03.02.05]
- Игорь Ковальчук — исполнительный директор транспортной компании ЗАО «Трансэк» [06.10.04]
- Игорь Ковальчук — генеральный директор транспортной компании "Трансэк" [24.04.06]

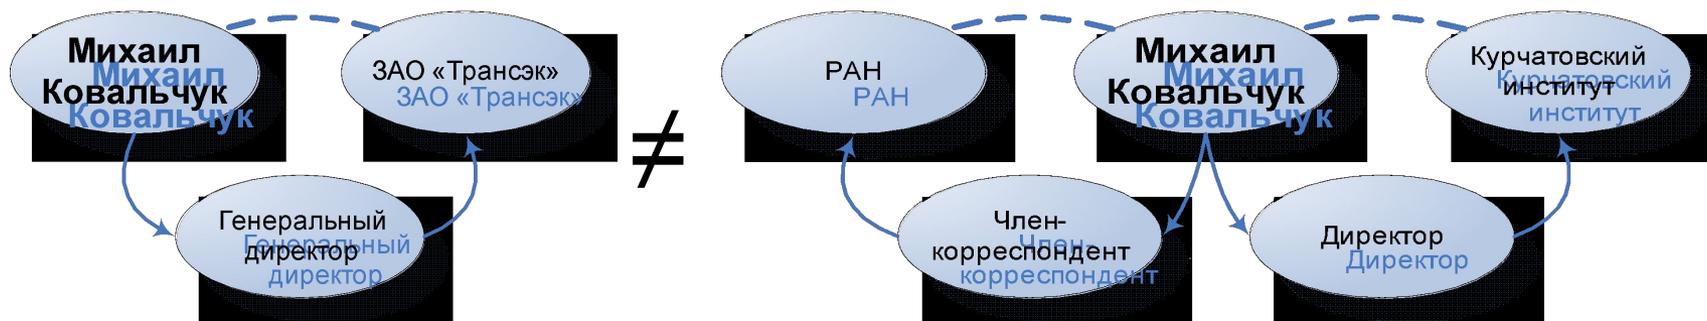
# Установление кореферентности (примеры)

- Модуль собирает в один объект разбросанную по разным текстам информацию об организации «Трансэк»:

Тип:	организация
Подтип:	транспортная_компания
Название	Трансэк
Правовая форма	ЗАО
Профиль	автотранспортные услуги
Локализация	Санкт-Петербург

- Ни один отдельно взятый текст не содержал полного набора сведений об этой компании

- Устанавливается, что существуют два разных лица с именем *Михаил Ковальчук*:



# Вывод новых фактов

Пример вывода новых фактов об отставках и назначениях на основе данных, содержащихся в разных текстах

- «Смена лиц, занимающих должность»

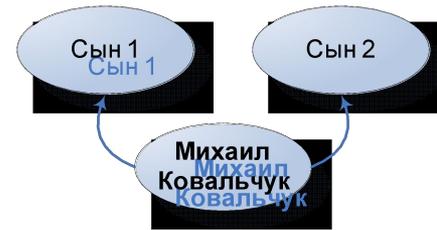


- «Смена должностей лица»



# Построение гипотез об отношениях между объектами из базы фактов

- По первому тексту система получает достоверный факт:
- Постулируется существование гипотетических объектов *Сын 1* и *Сын 2*, обладающих определенными свойствами, хоть и с разной степенью достоверности
- Поиск гипотетических объектов с такими свойствами в базе текстовых фактов обнаруживает два объекта:
- ...



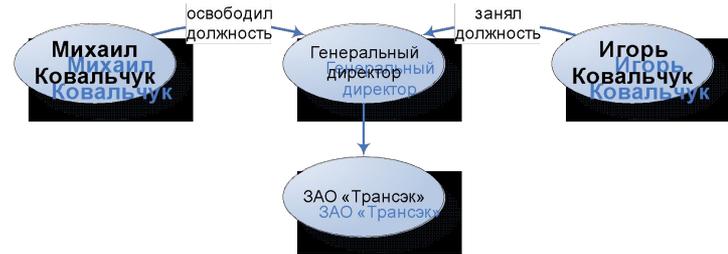
...	
Пол:	мужской
Отчество:	Михайлович
Фамилия:	Ковальчук
...	



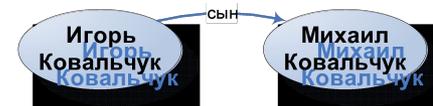
# Построение гипотез...

## (окончание)

- Система ранее вывела факт:
- Предположим, в знаниях системы о мире есть фрагмент, который позволяет строить гипотезы — например, такого рода:
- Строится гипотеза:
- Для подтверждения или опровержения этой гипотезы у системы пока нет данных. Но они могут появиться по мере поступления новых текстов.



*лицо, сменяющее однофамильца на руководящей должности с некоторой вероятностью состоит с ним в родственных отношениях*



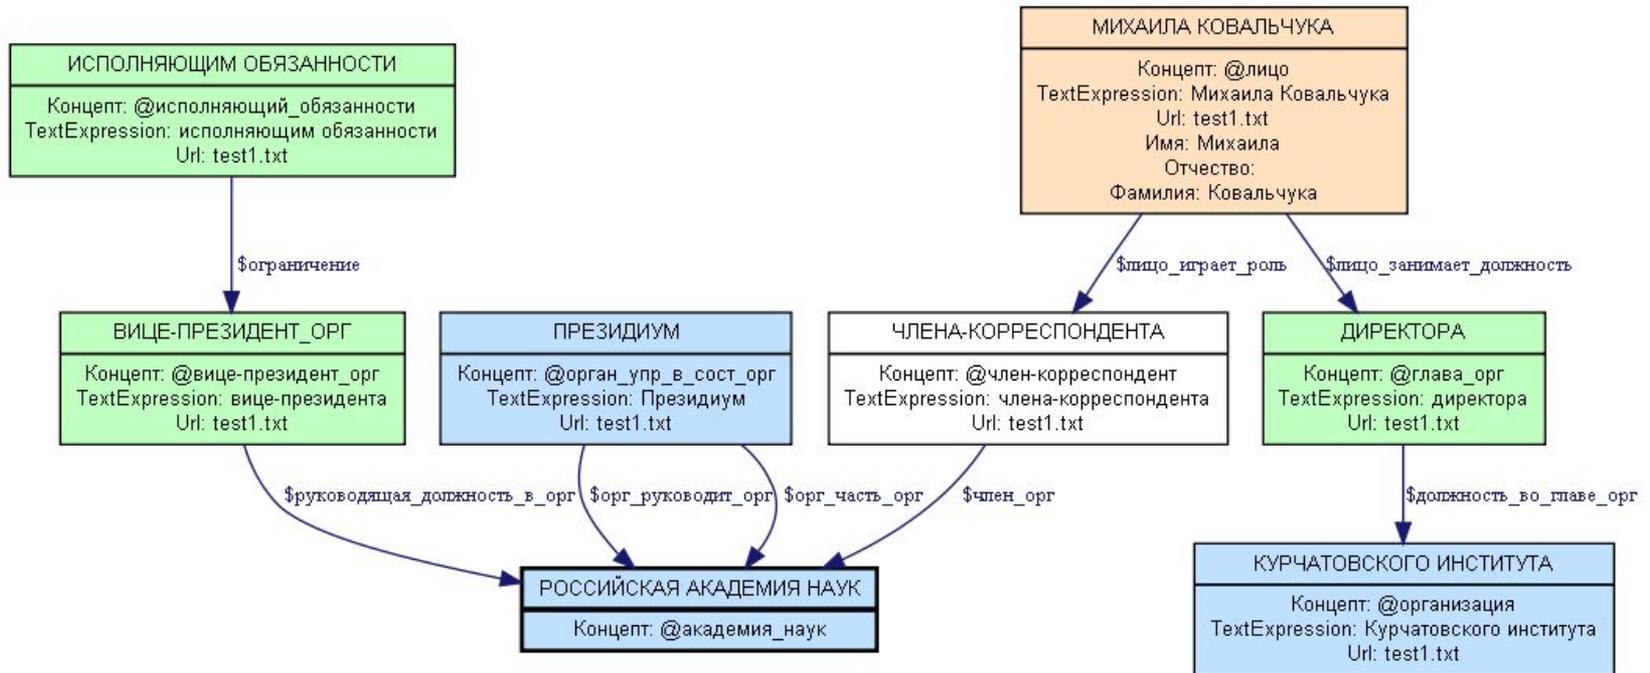
---

# Результаты извлечения информации

- Полученные результаты могут использоваться
- непосредственно — система выводит новые факты, распределенные по набору текстов, обеспечивает способ их визуализации
  - в качестве исходных данных для систем Data Mining — данные теперь структурированы
  - в качестве исходных данных для подсистемы индексирования — это даст новые возможности локального поиска
-

# Пример факта

*Президиум Российской академии наук решил назначить члена-корреспондента РАН, директора Курчатовского института Михаила Ковальчука исполняющим обязанности вице-президента РАН.*



---

# Установление кореферентности номинаций экземпляров

- Разрешение местоименной анафоры
- Установление тождества между номинациями экземпляров из одного текста

Иллюстрация ⇒

---



То, что 28-летний **Борис Ковальчук** будет назначен на эту должность, вопрос практически решенный, и его кандидатура проходит процедуру формального согласования в спецслужбах.

Его **отец**, **Юрий Ковальчук**, почетный консул Таиланда в Санкт-Петербурге, в 1996 году наряду с Владимиром Путиным и нынешним министром образования Андреем Фурсенко выступил соучредителем дачного кооператива "Озеро", а в 2000 году создал и возглавил центр стратегических разработок "Северо-запад".

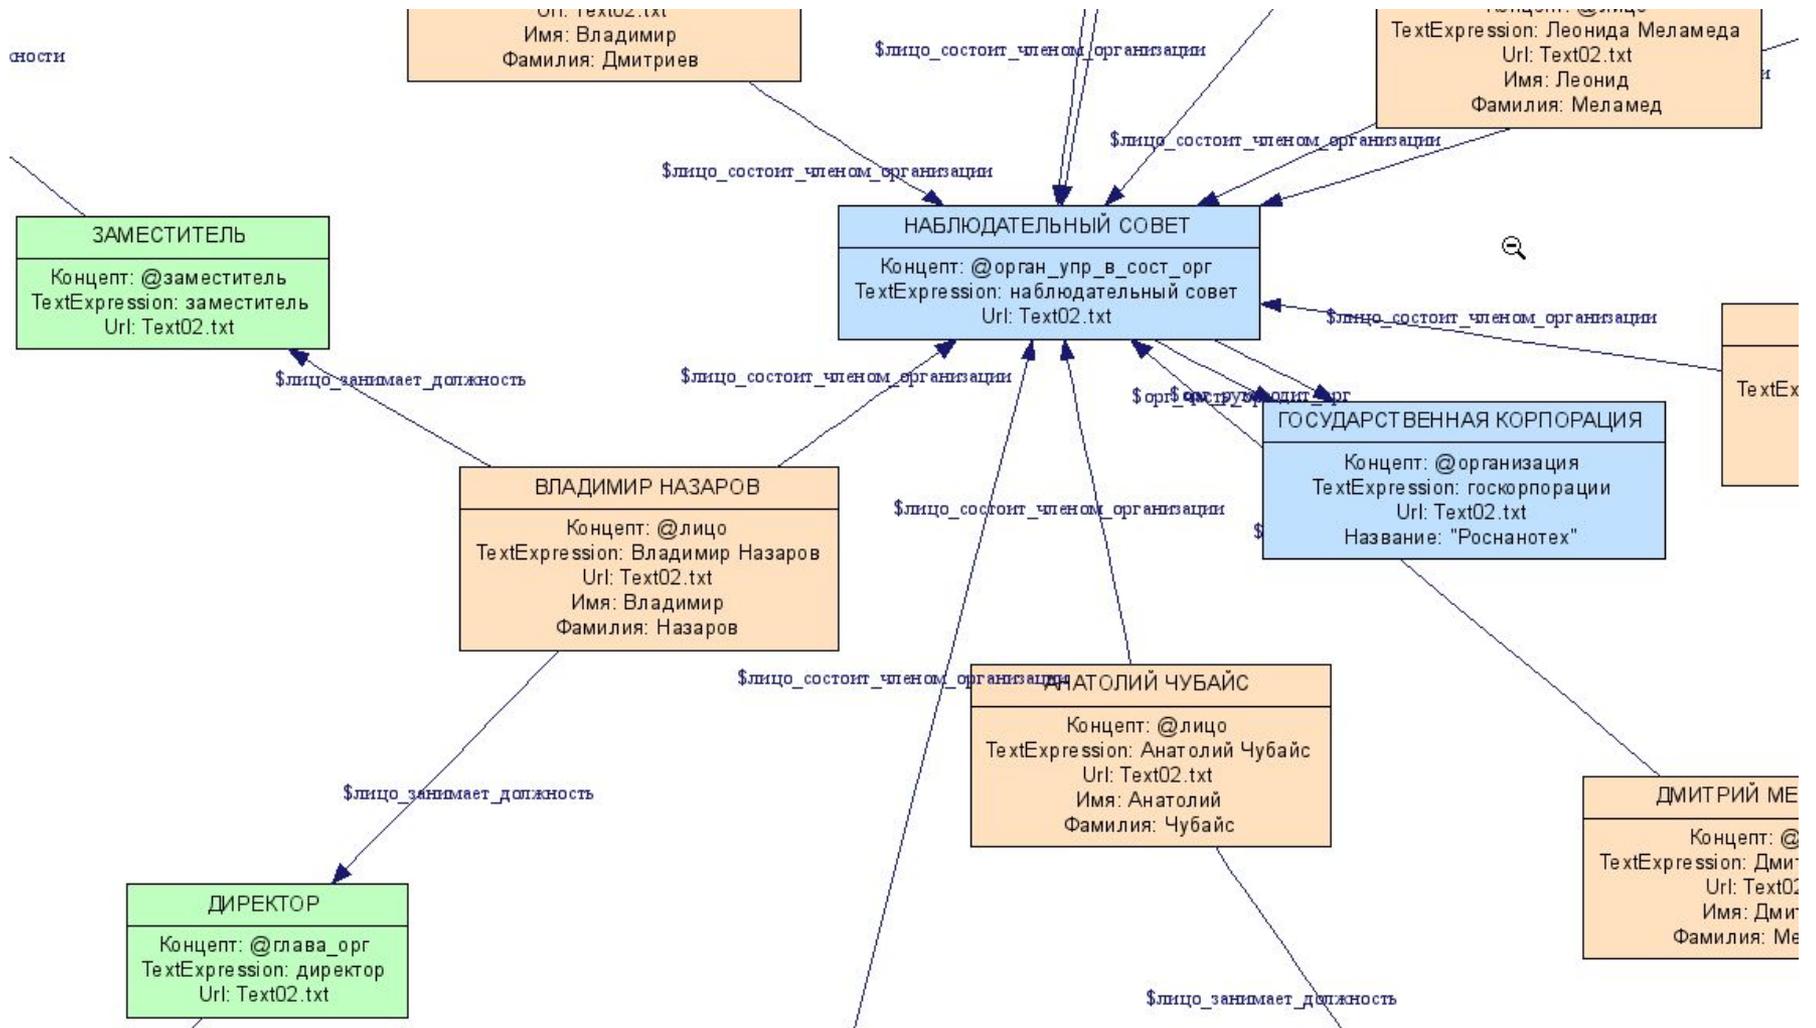
---

# Примеры

---



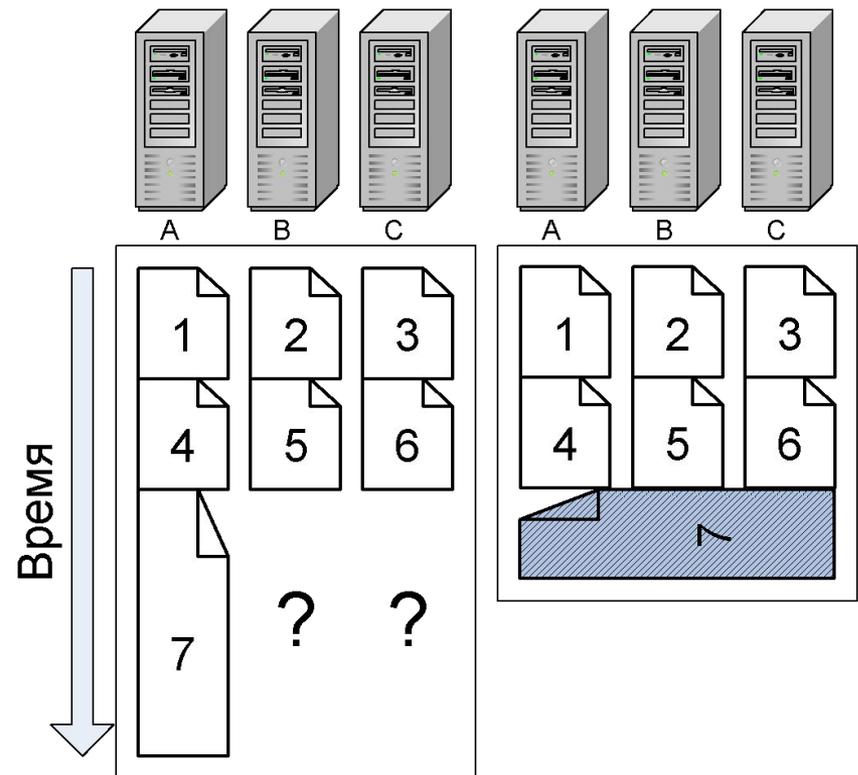




# ИСИДА-Т: Параллельная обработка

## ДАННЫХ

- Параллелизм на уровне документов для высокой производительности и снижения накладных расходов
- Разбиение документов для балансировки нагрузки
- Выделение сервисных узлов для выполнения отдельных функций по необходимости



# Параллельные вычисления

Параллельность в системе определяется спецификой конкретной задачи поиска и анализа информации. Выделяются следующие типы параллелизма:

- **по данным** (требуется обрабатывать независимые документы: индексация, извлечение информации...)
- **по задачам** (задачи загрузки документов, их индексации, каталогизации и поиска, работы с ресурсами знаний могут осуществляться независимо друг от друга)
- **по пользователям** (требуется обеспечить распределенную обработку запросов различных пользователей)
- **алгоритмический параллелизм** (некоторые алгоритмы, например вычисления прямого и обратного индекса, могут быть разбиты на параллельные блоки и исполняться на разных узлах)