

Извлечение информации (information extraction, IE)

Павел Браславский

Задача

- Неструктурированный текст → структурированное представление части информации
- Источники:
 - Новости
 - Википедия
 - Резюме
 - Научные статьи (биология, медицина)
 - Художественные произведения
- Результат
 - виден пользователям
 - для использования в других приложениях (поиск, вопросно-ответный поиск, ...)

Приложения

- аналитика
- интерфейс
- анализ тональности
- ПОИСК
 - вопросно-ответный поиск (QA)
 - поиск сущностей (entity search)

ПРИМЕРЫ

Годовая сумма выплат за 2013-2015 гг. составляла как минимум 75% свободного денежного потока оператора, но не менее 40 млрд руб.



MTS превзошла конкурентов по росту выручки от мобильной связи

Снижение капитальных затрат может хорошо отразиться на ее дивидендах

Таким образом, МТС отказывается от привязки дивидендов к свободному денежному потоку в пользу конкретного показателя выплаты на акцию. Этот переход должен обеспечить стабильный доход акционеров, пояснил сегодня журналистам вице-президент МТС по финансам и инвестициям Алексей Корня. По его словам, 25-26 руб. на акцию - это исторически максимальный уровень дивидендной доходности оператора. Выплаты на этом уровне компания хочет сохранить в течение следующих трех лет. При текущем количестве акций МТС это предполагает общую сумму дивидендных выплат в 50-52 млрд руб., добавляет Корня. Рекордными для МТС стали дивиденды, выплаченные по итогам 2014 г., - тогда ее акционеры получили 53,3 млрд руб., что составило 93,5% свободного денежного потока оператора. О том, что МТС в 2016 г. сохранит дивидендные выплаты на уровне прошлого года, 7

апреля заявил президент «АФК Система» (основной акционер МТС) Михаил Шамолин.

Кроме того, руководство МТС оставляет за собой возможность выкупить и погасить акции на 30 млрд руб. в течение трех ближайших лет, говорится в сообщении. У МТС нет обязательства совершать эту сделку, речь идет о возможности рассмотрения такого решения руководством компании, отмечает Алексей Корня. По его словам, МТС не относит выкуп акций к одному из условий выполнения прогноза по дивидендам, а рассматривает лишь как дополнительную опцию, которая позволит в случае благоприятных финансовых условий «заплатить акционерам еще больше». В этом случае сумма выплачиваемых дивидендов в абсолютном значении уменьшится, но доходность на акцию сохранится на прогнозируемом уровне - в 25-26 руб, отметил Корня.

Совет директоров рекомендовал собранию акционеров утвердить дивиденды за 2015 г. в размере 14,01 руб. на акцию (28,02 руб. на одну ADR). Общая сумма выплат акционерам в этом случае может составить 28 млрд руб. Выплатить эти деньги акционерам МТС предполагает до 1 августа 2016 г. МТС переходит к более равномерному распределению дивидендных выплат в течение года, говорится в сообщении компании. Год назад промежуточные дивиденды МТС за первое



ОАО АФК «Система» Диверсифицированный холдинг

- О компании | Пресс-релизы | Политика КСО | Кадровая политика

О компании

Основной акционер – Владимир Евтушенков (64,2%), около 19% торгуются на LSE в виде GDR, 5,2% - на Московской бирже.

Капитализация (LSE, 21 апреля 2015 г.) – \$3,5 млрд.

Финансовые показатели (US GAAP, 2014 г.):

выручка – \$16,6 млрд,

чистый убыток – \$3,3 млрд.

Образован в 1993 г., объединяет активы в различных отраслях, включая телекоммуникации и высокие технологии, энергетику, розничную торговлю. В числе активов холдинга доли в МТС (53% «Детском мире» (99%), «Медси» (75%), Башкирской электросетевой компании (91%) и др. (данные на 31 декабря 2014 г.).

Адвокат опроверг слухи об УДО бойца ММА Емельяненко [↗](#)

С чего всё началось

[Александр Емельяненко вышел из колонии по УДО](#)

Боец смешанных единоборств Александр Емельяненко, осужденный за насильственные действия сексуального характера, освобожден из колонии условно-досрочно. Об этом сообщил ТАСС источник, знакомый с ситуацией. ТАСС 13:18

Боец ММА Александр Емельяненко продолжает отбывать наказание в колонии, сообщил агентству "Р-Спорт" адвокат спортсмена Кахабер Долбадзе. Ранее источник РИА Новости в правоохранительных органах сообщил, что Емельяненко освобожден из колонии условно-досрочно. РИА Новости 14:16

ПОДРОБНЕЕ О СОБЫТИИ

[РОССИЙСКИЕ](#) [ДРУГИЕ ССЫЛКИ](#)



Вечерняя Москва

14:14

[Боец Александр Емельяненко досрочно освобожден из колонии](#)

Адвокат ММА

С чего

Алек

Боец с
действи
сообщ



Александр Емельяненко

Родился: 2 августа 1981 г. (35 лет), Старый Оскол, Белгородская область, СССР

Российский боец смешанных единоборств. Бывший чемпион мира по версии ProFC. Многократный чемпион России и мира по боевому самбо, чемпион Европы по боевому самбо, мастер спорта России по самбо, мастер спорта России международного класса по боевому самбо, мастер спорта России по дзюдо. [Википедия](#)

[Найти больше в Яндексе](#)

Боец ММА **Александр Емельяненко** продолжает отбывать наказание в колонии, сообщил агентству "Р-Спорт" адвокат спортсмена Кахабер Долбадзе. Ранее источник РИА Новости в правоохранительных органах сообщил, что **Емельяненко** освобожден из колонии условно-досрочно. РИА Новости 14:16

Адвокат опроверг слухи об УДО бойца ММА Емельяненко

С чего всё началось

Александр Емельяненко вышел из колонии

Боец смешанных единоборств Александр Емельяненко, осужденный за действия сексуального характера, освобожден из колонии условно-досрочно, сообщил ТАСС источник, знакомый с ситуацией. ТАСС 13:18

Боец MMA Александр Емельяненко продолжает отбывать наказание, сообщил агентству "Р-Спорт" адвокат спортсмена Кахабер... РИА Новости в правоохранительных органах сообщил, что Емельяненко освобожден из колонии условно-досрочно. РИА Новости 14:16



Федор Емельяненко

Родился: 28 сентября 1976 г. (40 лет), Рубежное, Луганская область, Украинская ССР, СССР

Российский спортсмен, четырёхкратный чемпион мира по MMA в тяжёлом весе по версии «Pride FC», двукратный - по версии «RINGS», двукратный - по версии «WAMMA», четырёхкратный чемпион мира и девятикратный чемпион России по боевому самбо. Заслуженный мастер спорта по самбо и мастер спорта международного класса по дзюдо. [Википедия](#)

[Найти больше в Яндексе](#)

ОБЩЕСТВО

Гайдар Мария Егоровна

дочь политика ([219 упоминаний в СМИ](#))

...Как сообщила РИА "Новости" *дочь политика Мария Гайдар*, ее отец лежит под капельницей по восемь часов в день....

01.12.06 [СМИ.ru](#)

молодежный политик ([5 упоминаний](#))

... *Молодежные политики Маша Гайдар* и Илья Яшин висят

под мостом... 23.11.06 [Клерк.Ру](#)

Работа

Места работы отсортированы по количеству упоминаний

Демократическая Альтернатива, лидер ([347 упоминаний в СМИ](#) с 10.06.2005 по 08.12.2006)

...23 ноября *лидер* молодежного движения "*Демократическая Альтернатива*" *Мария Гайдар* и Илья Яшин с помощью альпинистского снаряжения спустились с Большого Каменного моста и больше часа продержали десятиметровый транспарант с лозунгом "Верните народу выборы, гады" над Москвой-рекой.... 24.11.06 [Томский Обзор](#)

СПС, член ([57 упоминаний](#) с 12.06.2005 по 23.11.2006)

...Ежедневный журнал, 23.11.06Никита Белых, лидер партии СПС (Союз Правых Сил), об акции протеста против выборного законодательства, одним из организаторов которой стала *Мария Гайдар*, лидер молодежного движения "Да!" и *член* партии СПС: Тут два момента по существу вопроса- очевидно, что мы полностью поддерживаем

Связанные люди

Егор Гайдар

...- Мария Гайдар, дочь бывшего премьер-министра РФ Егора Гайдара.... [Эхо Москвы в Перми](#)



[Подписка на новости](#)



[Новости на вашем сайте](#)

Случаются ошибки :)

Яндекс меня похоронил :)

Гайдар Мария Егоровна

Дата смерти — 23.11.2006

... Лидер молодежного "Яблока" Илья Яшин и координатор молодежного движения "Да" Мария Гайдар повесились сегодня в полдень под Большим Каменным мостом.... 23.11.06

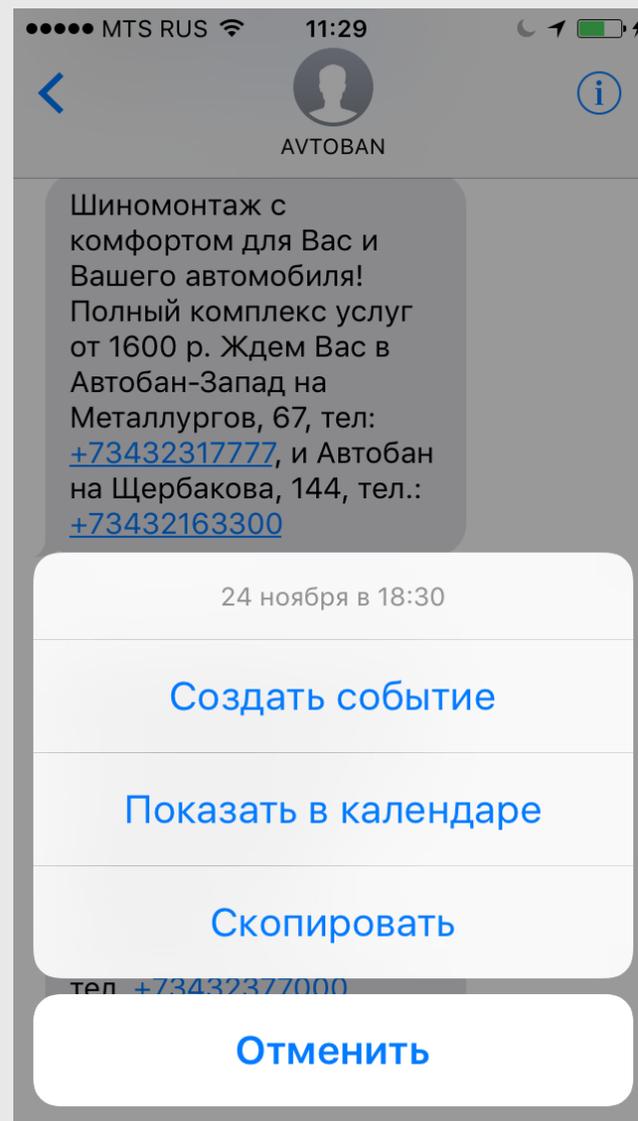
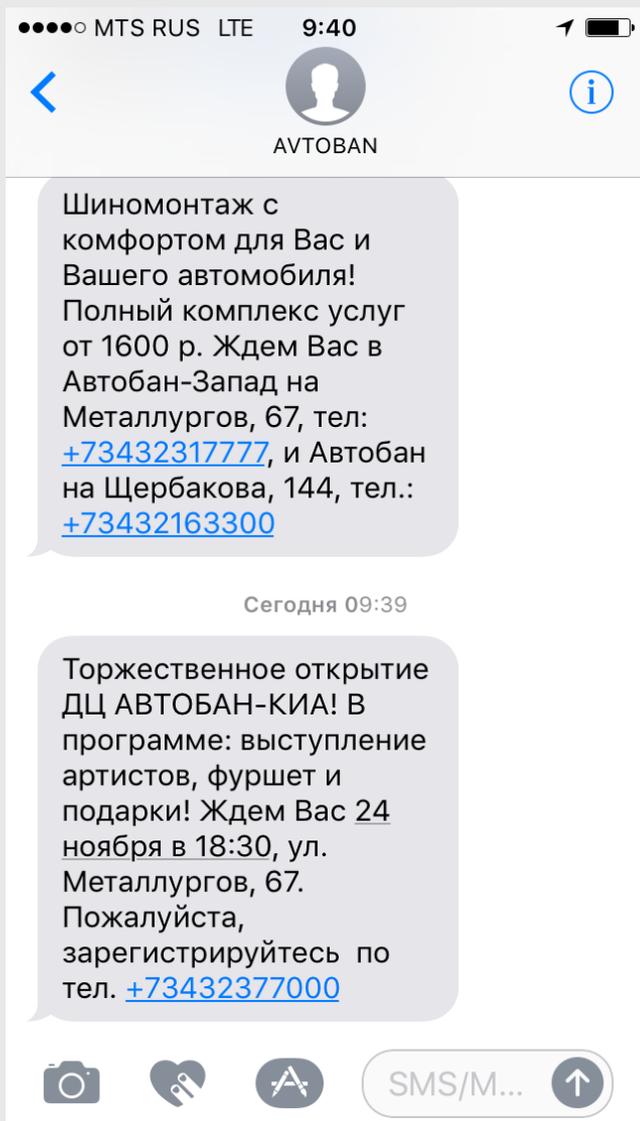
http://news.yandex.ru/people/gajdar_mariya.html



 **m_gaidar**

8 декабря, 2006

24 часа	Неделя (02.11.16 - 08.11.16)	Месяц (09.10.16 - 08.11.16)
1. Tele2 15	1. Tele2 468	1. Tele2 2576
↑ ! 2. оператор Tele2 5	↑ +10 2. тв 143	2. Мегафон 532
↑ ! 3. mvno 5	↑ +6 3. delfi 138	3. МТС 498
↑ ! 4. Мегафон 4	↑ +4 4. фото 137	4. delficoобщите 357
↑ ! 5. Ростелеком 4	↓ -1 5. delficoобщите 137	5. ECA 354
↑ ! 6. роскомнадзор 4	↑ ! 6. концерн Eesti Energia 134	6. сеть Tele2 345
↑ ! 7. Группа ВТБ 4	↑ +11 7. Коммерческий 134	7. филиал Tele2 339
↑ ! 8. Альфа-групп 3	↑ +2 8. РЖД 134	8. фото 306
↑ ! 9. компания tele2 3	↑ ! 9. Eesti Raudtee 134	9. delfi 303
↑ ! 10. ВТБ 3	↑ ! 10. h&m 134	10. РЖД 281
↑ ! 11. Альфа 3	↑ ! 11. The Global Service Design Award 134	11. Вымпелком 265
↑ ! 12. МТС 3	↑ ! 12. taxify 134	12. тв 265
↑ ! 13. Гамма 3	↑ +4 13. центр Arsenal 134	13. Samsung 255
↑ ! 14. пресс-служба " Ростелеком 3	↓ -9 14. ECA 134	14. Билайн 249
↑ ! 15. компания - Иркутский научно-исследовательский институт 3	↑ ! 15. keskus 134	15. Swedbank 246
↑ ! 16. Turkcell 3	↑ ! 16. Айдар 133	16. Tallinn 234
↑ ! 17. АО " Иргиредмет 3	↑ ! 17. CETA 130	17. центр Arsenal 229
↑ ! 18. филиал " Урал 3	↑ ! 18. Tesla 128	18. Коммерческий 228
↑ ! 19. СТН 3	↑ ! 19. Талант 126	19. Marat 216
↑ ! 20. компания Turkcell 3	↑ +1 20. Eesti Energia 120	20. Какой 213
↑ ! 21. Henri Service Ltd 2	↑ ! 21. правление Atrium 120	21. Eesti Energia 213
↑ ! 22. Nadash International Holdings 2	↑ ! 22. компания Linda Line 119	22. оператор Tele2 212
↑ ! 23. альянс " МегаФон 2	↓ -10 23. Samsung 118	23. Ведомость 211
↑ ! 24. пресс-служба АО " Иргиредмет 2	↑ ! 24. Банк Эстония 116	24. компания Tele2 208



Ответы

The screenshot shows a Google search interface. The search bar contains the text "iphone 6 weight" and a magnifying glass icon. Below the search bar are navigation tabs: "All" (underlined), "News", "Shopping", "Books", "Images", "More", and "Search tools". The search results indicate "About 66,100,000 results (0.58 seconds)". A featured snippet is displayed in a white box with a light gray border, containing the text: "The iPhone 6 measures 5.44 x 2.64 x 0.27 inches (138.1 x 67 x 6.9mm) and weighs **4.55 ounces (129g)** – a weight increase that is roughly proportional to its 16% volume increase compared to the iPhone 5S. Sep 9, 2014". Below the snippet is a search result from Forbes: "iPhone 6 vs iPhone 6 Plus: The Differences Between The ..." with the URL "www.forbes.com/.../iphone-6-vs-iphone-6-plus-what-is-the-differenc..." and a "Forbes" logo. A "Feedback" link is located below the Forbes result. At the bottom, another search result is visible: "iPhone 6 - Technical Specifications - Apple" with the URL "www.apple.com > iPhone > iPhone 6" and the text "Weight: **4.55 ounces (129 grams)** 6.22 inches (158.1 mm) 3.06 inches (77.8 mm) 0.28 inch."

Поиск сущностей

дочь первого космонавта ✕ ↔ Найти Логин

поиск КАРТИНКИ ВИДЕО КАРТЫ МАРКЕТ НОВОСТИ ПЕРЕВОДЧИК ЕЩЁ

Интерес к семье первого космонавта (жене Валентине...)
vlasti.net > news/84780 ▾
Воспоминаниями о том, как сложилась судьба семьи **первого космонавта**, с ...
Старшая **дочь** Гагариных Елена так вспоминала жизнь в Звездном городке: «Там...

Галина Юрьевна Гагарина, младшая дочь первого...
fishki.net > 1562133_iurii_i_pervogo_kosmonavta.html =



Елена Юрьевна Гагарина
Генеральный директор Государственного историко-культурного музея-заповедника «Московский Кремль», искусствовед. Старшая дочь первого космонавта планеты Юрия Гагарина. [Википедия](#)
Родилась: 17 апреля 1959 г. (57 лет), [Заполярный](#), Мурманская область, РСФСР, СССР
Родители: [Валентина Ивановна Гагарина](#), [Юрий Гагарин](#)
Дети: Екатерина Караваева

папа леонардо ди каприо 🔍

All Videos Images News Maps More ▾ Search tools

About 283,000 results (0.40 seconds)

Leonardo DiCaprio / Father



George DiCaprio

George Paul DiCaprio is an American writer, editor, publisher, and distributor, known for his work in the realm of underground comix, where he collaborated with such notables as Timothy Leary and Laurie Anderson. [Wikipedia](#)

⏪ More about George DiCaprio Feedback


[из лекции об информационном поиске]

БАЗА ЗНАНИЙ (KNOWLEDGE BASE)

Freebase

[Browse](#) [Query](#) [Help](#)[Sign In or Sign Up](#)[English](#) ▾

Important! Freebase is read-only and will be shut-down. [More](#).



Topic

Elvis Presley ^{en}

mid: /m/02jq1 notable type: /music/artist on the web: [Wikipedia.org](#)

Elvis Aaron Presley was an American singer and actor. Regarded as one of the most significant cultural icons of the 20th century, he is often referred to as "the King of Rock and Roll", or simply, "the King". Born in Tupelo, Mississippi, Presley and his family moved to Memphis, Tennessee, when he was 13 years old. His music career began there in 1954, when he started to work with Sam Phillips, the owner of Sun Records. Accompanied by guitarist Scotty Moore and bassist Bill Black, Presley was an early popularizer of rockabilly, an uptempo, backbeat-driven fusion of country music and rhythm and blues. RCA Victor acquired his contract in a deal arranged by Colonel Tom Parker, who was to manage the singer for more than two decades. Presley's first RCA single, "Heartbreak Hotel", released in January 1956, was a number-one hit in the US. He became the leading figure of rock and roll after a series of network television appearances and chart-topping records. [-]

Created by [mwcl_musicbrainz](#) on 9/27/2013

[Properties](#)[118n](#)[Keys](#)[Links](#)

Filter options: Show all domains and properties

Common /common

Freebase Commons

Topic /common/topic

X

Also known as /common/topic/alias

Also known as

- Elvis
- Elvis Aron Presley
- The King of Rock 'n' Roll
- Elvis Aaron Presley
- King of Rock and Roll
- Elvis, the pelvis
- The King
- The King of Rock and Roll
- "The Pelvis "

[44 values total](#)

Description /common/topic/description

Elvis Aaron Presley was an American singer and actor. Regarded as one of the most significant cultural icons of the 20th century, he is often referred to as "the King of Rock and Roll", or simply "the King".

Types:

Common
Topic

Film
Film music contributor
Film actor
Film subject
Person or entity appearing in film
Film song performer

Music
Musical Artist
Musician
Composer
Lyricist
Featured artist

Business
Product theme



About: Юрий Алексеевич Гагарин

[Goto](#) [Sponge](#) [NotDistinct](#) [Permalink](#)

An Entity of Type : <http://www.wikidata.org/ontology#Item>, within Data Space : dbpedia.org associated with source [document\(s\)](#)

Type: Command:

Attributes Values

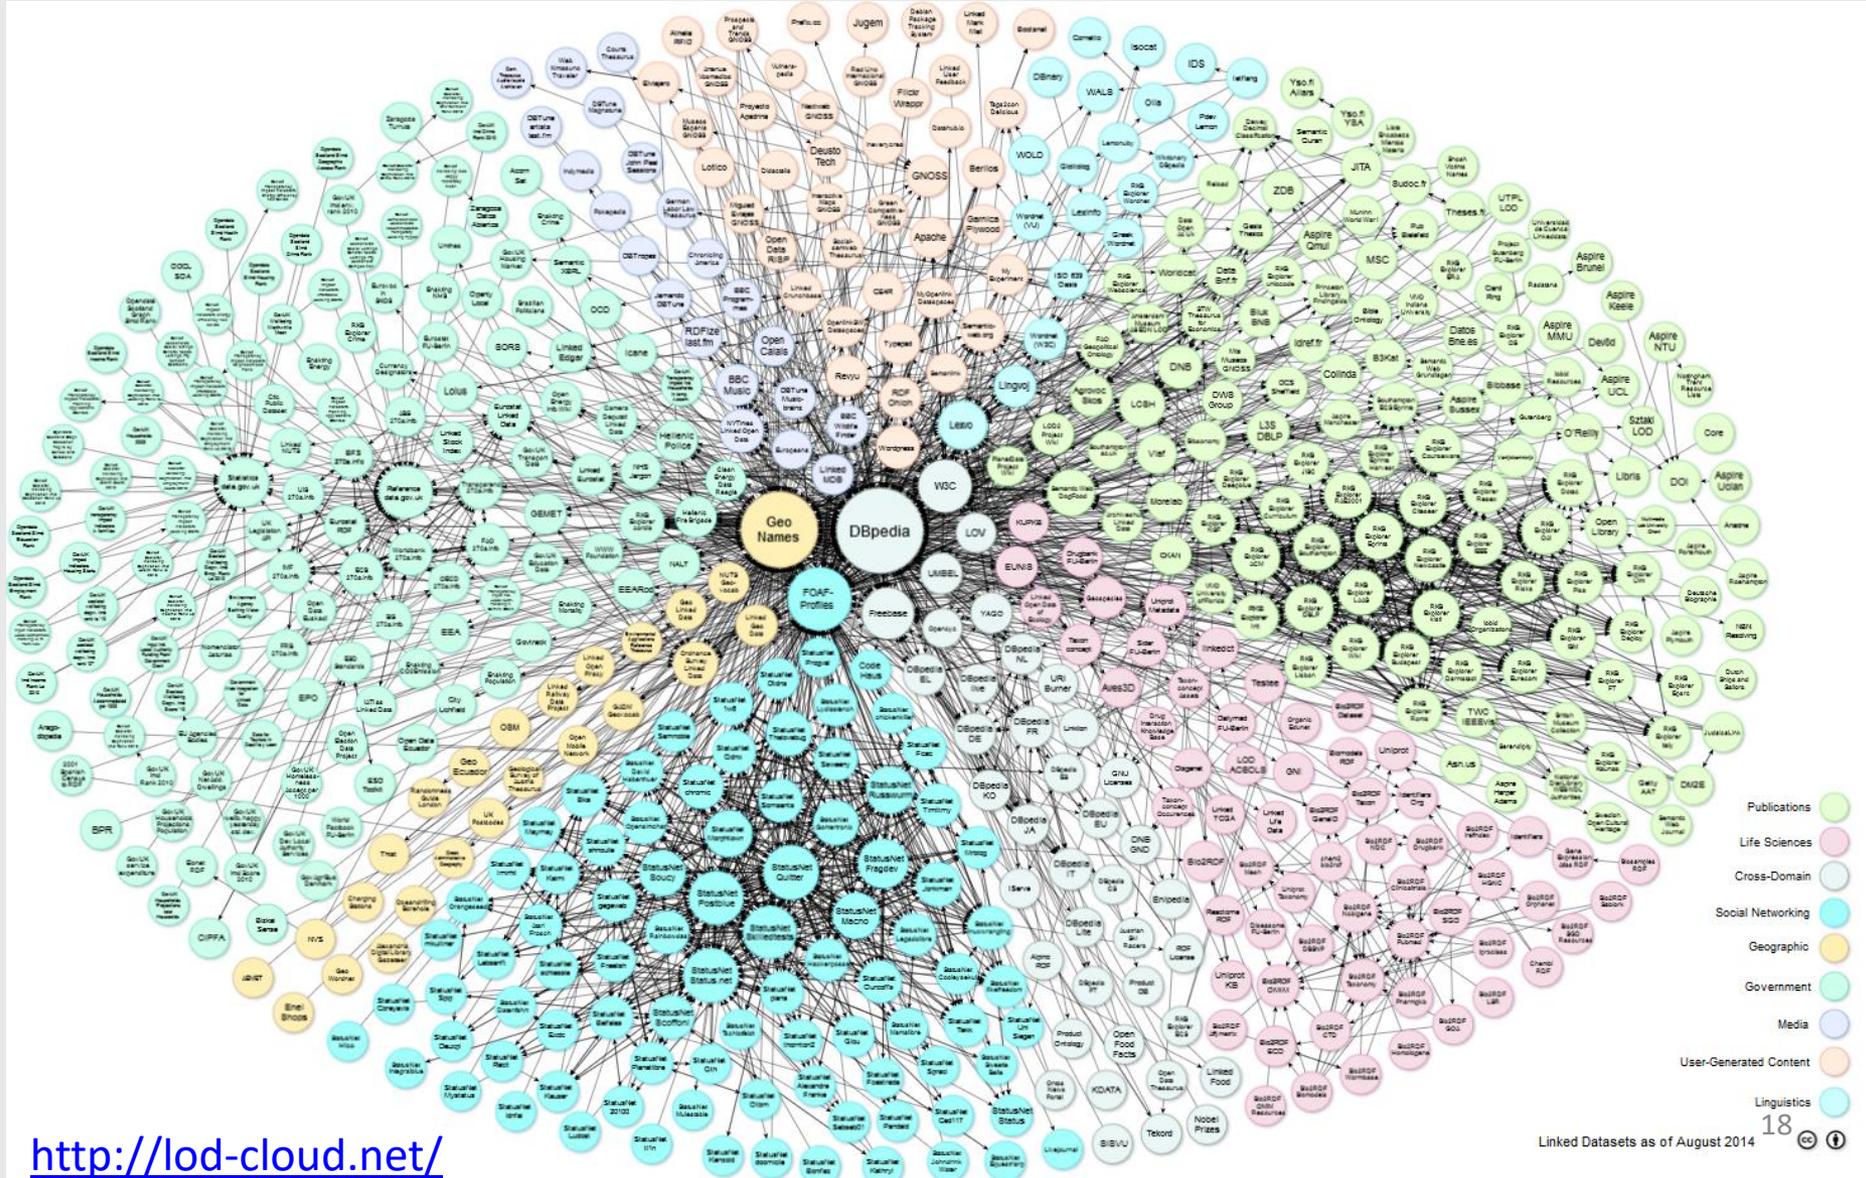
[type](#) [Человек](#)
<http://www.wikidata.org/ontology#Item>

[wikidata:P1741c](#) 100616

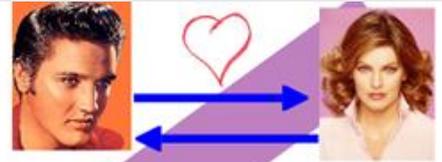
[label](#) Yuri Gagarin
 Yuri Gagarin
 Yuri Gagarin

wikidata:P119c	Некрополь у Кремлёвской стены
wikidata:P227c	118537105
wikidata:P241c	Центр подготовки космонавтов имени Ю. А. Гагарина Военно-воздушные силы СССР
wikidata:P245c	500342574
wikidata:P26c	Гагарина, Валентина Ивановна
wikidata:P40c	Гагарина, Елена Юрьевна
wikidata:P935c	Юрий Алексеевич Гагарин
wikidata:P535s	wikidata:Q7327577B6D582-2641-4454-AA9A-A11CFE480837
wikidata:P1263c	666/000026588

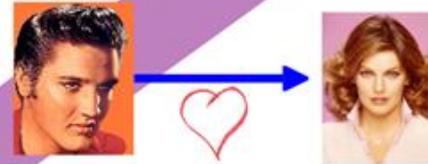
Linked Open Data (LOD)



Reasoning



Fact Extraction



Instance Extraction



Entity Disambiguation



singer Elvis

Entity Recognition

Knowledge Representation

[Suchanek]

ИМЕНОВАННЫЕ СУЩНОСТИ (NAMED ENTITIES)

Именованные сущности (NEs)

- Люди
- Организации
 - Фирмы
 - Правительственные организации
 - Газеты
 - Спортивные клубы
- Бренды
- Место (адрес, географический объект)
- События
- Даты
- Вес/цена/...

IO/BIO-разметка

Tag	Meaning
O	Not part of a named entity
B-PER	First word of a person name
I-PER	Continuation of a person name
B-LOC	First word of a location name
I-LOC	Continuation of a location name
B-ORG	First word of an organization name
I-ORG	Continuation of an organization name
B-MISC	First word of another kind of named entity
I-MISC	Continuation of another kind of named entity

[Goldberg]

Пример

textocat.ru/demo/ Поиск

Выделение упоминаний сущностей

1 Таким образом, **МТС** отказывается от привязки дивидендов к свободному денежному потоку в пользу конкретного показателя выплаты на акцию. Этот переход должен обеспечить стабильный доход акционеров, пояснил сегодня журналистам вице-президент **МТС по финансам и инвестициям Алексей Корня**.

Назад к тексту

Построено на [Textocat API](#)

eurekaengine.ru/ru/demo/ Поиск

Определение имен собственных (NER)

Таким образом, **МТС** отказывается от привязки дивидендов к свободному денежному потоку в пользу конкретного показателя выплаты на акцию. Этот переход должен обеспечить стабильный доход акционера, пояснил сегодня журналистам вице-президент **МТС по финансам и инвестициям Алексей Корня**.

◆ Физ. лица ◆ Юр. лица ◆ Гео. объекты ◆ События ◆ Торговые марки

Пример

Stanford CoreNLP

Please enter your text here:

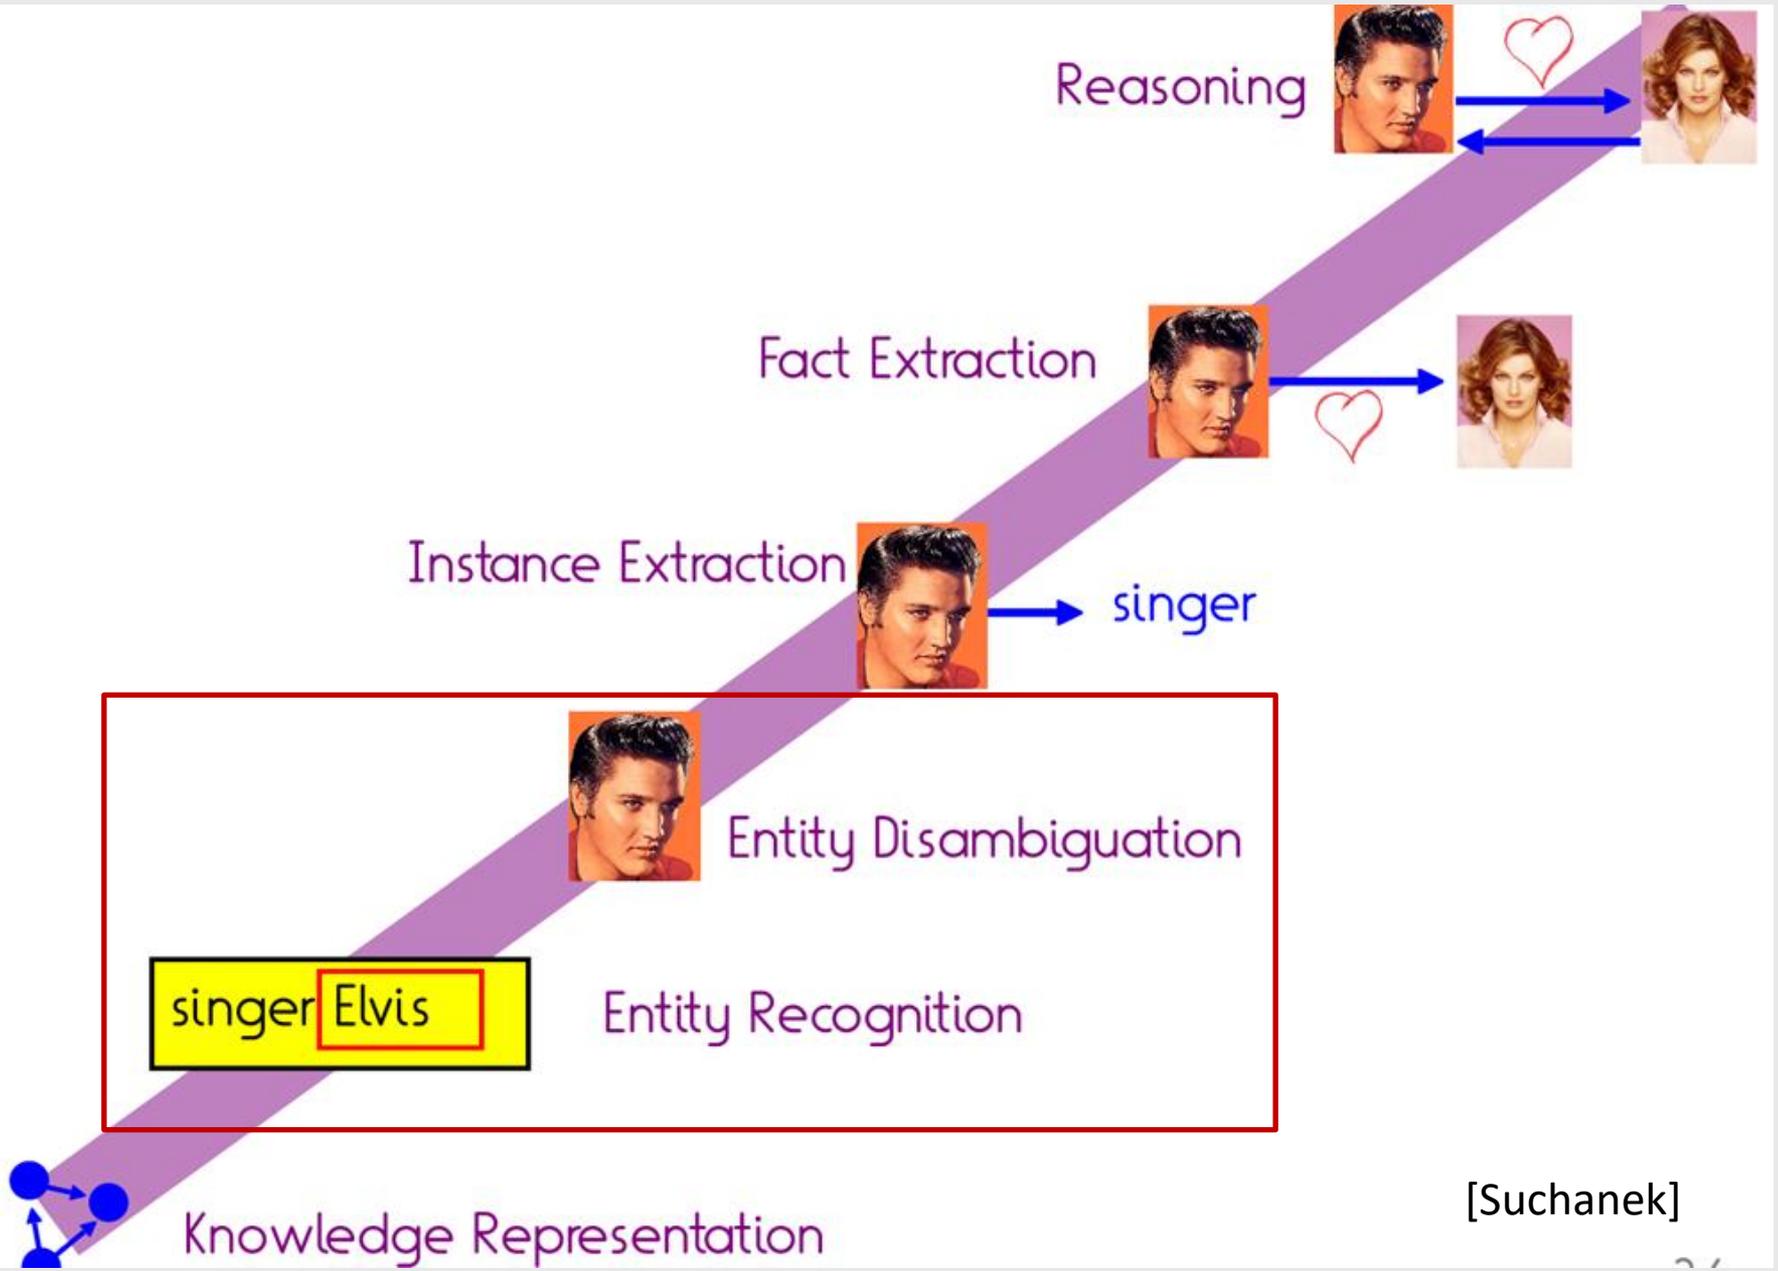
But among people who have spent years in the tech industry, Intuit is just as memorable for being the company that got away from Microsoft in the mid-1990s — a rare moment when Bill Gates's giant, at the peak of its influence, did not get its way.

named entities x

Submit

Named Entity Recognition:

1 But among people who have spent DURATION years in the tech industry, ORGANIZATION Intuit is just as memorable for being the company that got away from ORGANIZATION Microsoft in the DATE mid-1990s -- a rare moment when PERSON Bill Gates's giant, at the peak of its influence, did not get its way .



[Suchanek]

Методы

- Регулярные выражения/шаблоны
- Словари (газетир, gazetteer)
- Классификация
- Методы на последовательностях:
 - Марковские модели
 - Условные случайные поля (Conditional Random Fields, CRF)
 - нейронные сети
- Обучение шаблонов

GeoNames

[\[advanced search\]](#)

43 records found for "Yekaterinburg"

Name	Country	Feature class	Latitude	Longitude
1  Yekaterinburg  Catharinoburgum,Ekaterimburgo,Ekaterinburg,Ekaterinburgo,Iekaterinbourg,Jekaterinburg,Jekaterinburga...	Russia , Sverdlovsk	seat of a first-order administrative division population 1,349,772	N 56° 51' 6"	E 60° 36' 43"
2  Yekaterinburg-Sortirovochnyy Stancija Sverdlovsk-Sortirovochnyj,Stantsiya Sverdlovsk-Sortirovochnaya,Stantsiya Sverdlovsk-Sortiro...	Russia , Sverdlovsk	railroad station	N 56° 52' 56"	E 60° 28' 24"
3  Yekaterinburg-Passazhirskiy Stancija Ekaterinburg-Passazhirskij,Stancija Sverdlovsk-Passazhirskij,Stantsiya Sverdlovsk-Passazhir...	Russia , Sverdlovsk	railroad station	N 56° 51' 32"	E 60° 36' 19"
4  Khim mash Khimash,Khim mash,Nizhneisetskiy,Nizhni Izetsk,Хим маш	Russia , Sverdlovsk	section of populated place	N 56° 45' 22"	E 60° 42' 15"
5  Yelizavetinskiy Elizabet,Elizavetinskiy,Yelasavetinsk,Yelizabet,Yelizat,Yelizavet,Yelizavetinskiy,Елизаветинский	Russia , Sverdlovsk	section of populated place	N 56° 44' 49"	E 60° 36' 48"
6  Gornozavodskiy Gornozavodskij,Gornozavodskiy,Poselok Gornozavodskiy,Poselok Gornozavodskiy,Горнозаводский	Russia , Sverdlovsk	section of populated place	N 56° 52' 0"	E 60° 35' 30"
7  Pyshma Pyshma,Пышма	Russia , Sverdlovsk	section of populated place	N 56° 56' 5"	E 60° 36' 49"
8  Novyy Novyj,Новуу,Новый	Russia , Sverdlovsk	section of populated place	N 56° 53' 51"	E 60° 38' 0"
9  Chermet Chermet,Чермет	Russia , Sverdlovsk	section of populated place	N 56° 46' 42"	E 60° 34' 58"
10  Moskovskiy	Russia ,	section of	N 56° 48' 13"	E 60° 30' 9"

Признаки

- Слова окружения (+/-)

*директор, начальник, представитель...
компания, ООО, ПАО, фирма, ...*

- Части речи
заявил/сказал/прибыл

- Структура

*А. С. Пушкин, Михаил Лермонтов
Windows 10, iPhone 7*

*3.11.2016, (812) 212-85-06
Литейный пр-т, 24*

NN4NER

- Lample et al., 2016
- две архитектуры:
 - LSTM-CRF*
 - Stack LSTM (~shift-reduce parsers)
- контекст, w2c + character-based representation
- 4 языка (Dutch, German, Spanish, English)
- результаты близкие или превосходящие SoA

Снятие неоднозначности

Иванов, Сергей

Материал из Википедии — свободной энциклопедии

(перенаправлено с «Сергей Иванов»)

Стабильная версия была проверена 12 августа 2016. Имеются непроверенные изменения в шаблонах или

В Википедии есть статьи о других людях с фамилией Иванов.

Серге́й Ивано́в:

- **Иванов, Сергей Александрович:**

- **Иванов, Сергей Александрович** (1859—1927) — русский революционер, народоволец, заключённый Шлиссельбург
- **Иванов, Сергей Александрович** (1870—1918/1919) — российский военно-морской деятель, контр-адмирал.
- **Иванов, Сергей Александрович**

- **Иванов, Сергей Алексеевич:**

- **Иванов, Сергей Алексеевич** (18
- **Иванов, Сергей Алексеевич** (18

- **Иванов, Сергей Анатольевич:**

- **Иванов, Сергей Анатольевич** (1
- **Иванов, Сергей Анатольевич** (р
- **Иванов, Сергей Анатольевич** —
- **Иванов, Сергей Анатольевич** — администратии в 2005—2006 г

- **Иванов, Сергей Андреевич:**

- **Иванов, Сергей Андреевич** (род. 1978) — российский игрок в мини-футбол.
- **Иванов, Сергей Андреевич** (1922—1989) — Герой Советского Союза.

Задорнов

Материал из Википедии — свободной энциклопедии

[\[править\]](#) | [править вики-текст](#)

Задóрнов — русская фамилия. Известные носители:

- **Задорнов, Михаил Михайлович** (род. 1963) — российский политический деятель, в 1997—1999 — министр финансов РФ.
- **Задорнов, Михаил Николаевич** (род. 1948) — русский писатель-сатирик, сын Н. П. Задорнова.
- **Задорнов, Николай Павлович** (1909—1992) — русский писатель.

ИЗВЛЕЧЕНИЕ ОТНОШЕНИЙ (RELATION EXTRACTION)

20.10.2016, 11:59

Nissan приобрел контрольный пакет акций Mitsubishi Motors



1

Компания Nissan приобрела контрольный пакет акций японского концерна Mitsubishi Motors, заявил глава Nissan Motor и Renault Карлос Гон. Речь идет о 34% акций автопроизводителя. Господин Гон получил должность председателя совета директоров Mitsubishi Motors, в которую вступит с 14 декабря.

Помимо этого Nissan приобрел акции в Mitsubishi Corp., Mitsubishi Heavy Industries Ltd и Bank of Tokyo-Mitsubishi UFJ. Сообщается, что нынешний председатель совета директоров и президент Mitsubishi Motors Осама Масуко останется после завершения сделки на посту президента японской компании.

В рамках совместной работы Nissan и Mitsubishi намерены обмениваться технологиями, платформами и наработками по созданию электромобилей.

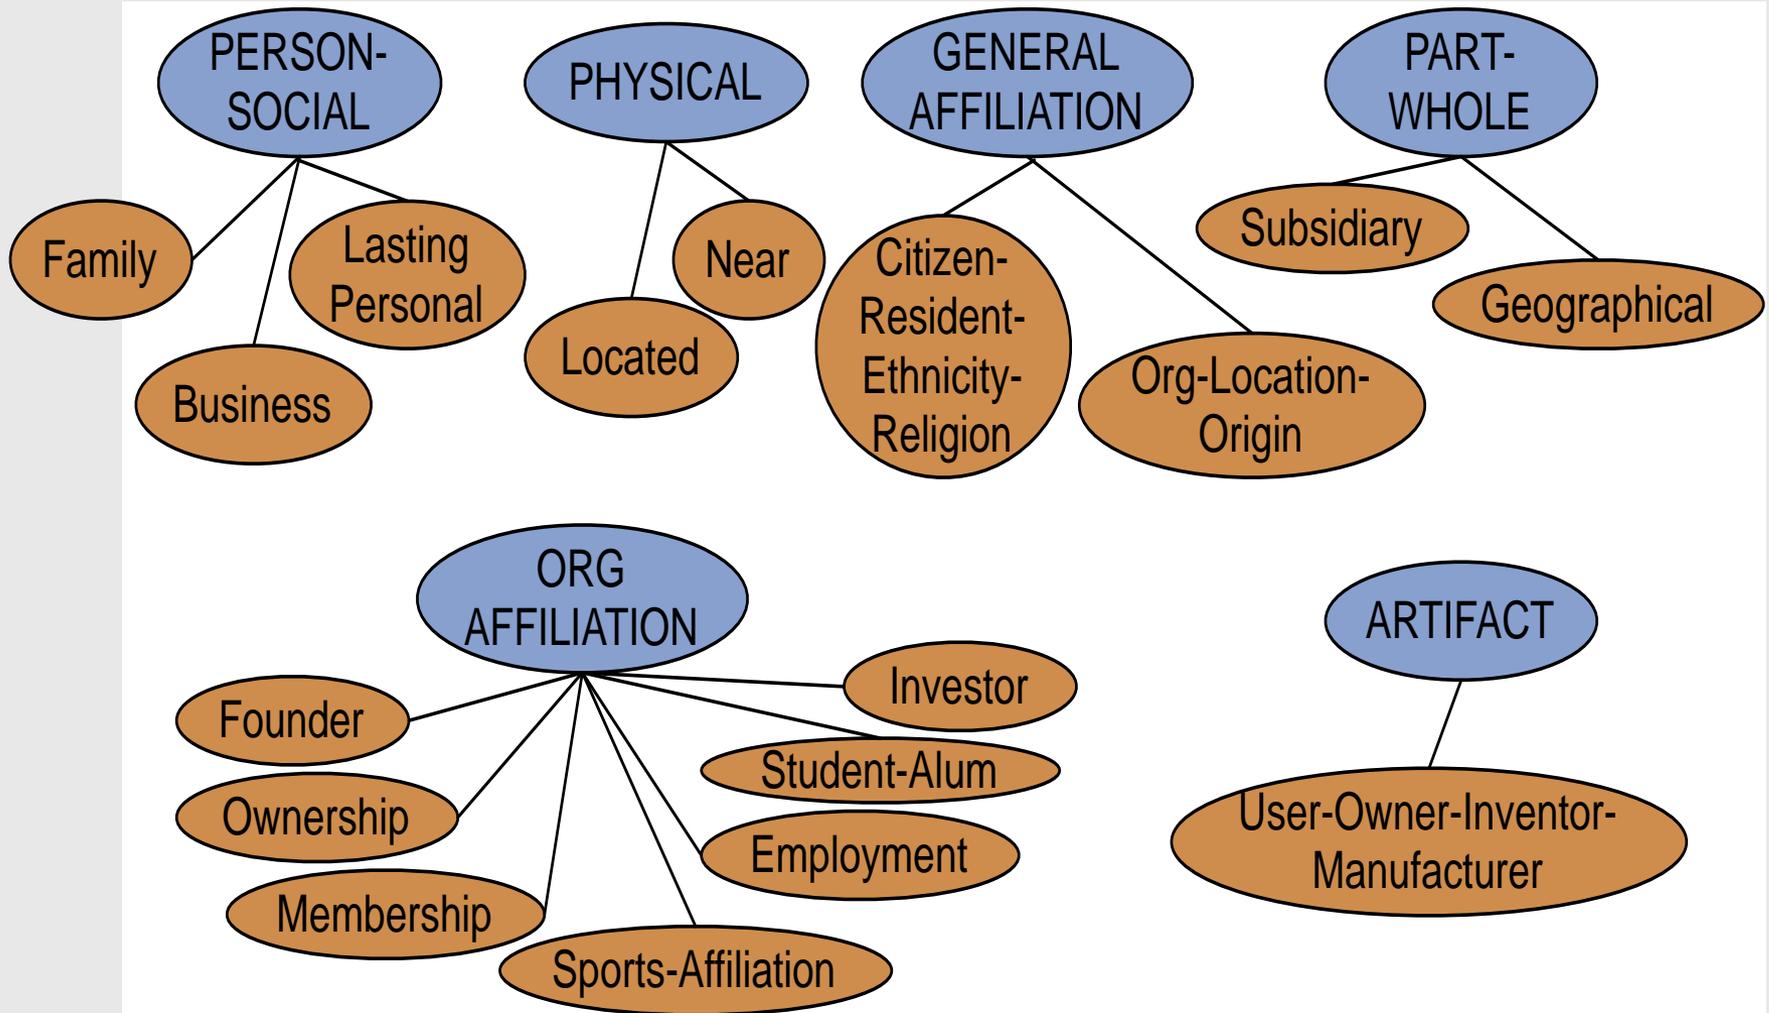
В текущем году компания Mitsubishi Motors впервые за восемь лет несет убытки из-за того, что в апреле призналась в фальсификации результатов тестов и искажении данных по экономичности двигателей автомобилей. Ожидается, что под руководством господина Гона Mitsubishi сможет поправить пошатнувшееся финансовое положение, а Nissan сможет расширить присутствие на тех рынках, где ранее популярностью пользовалась Mitsubishi.

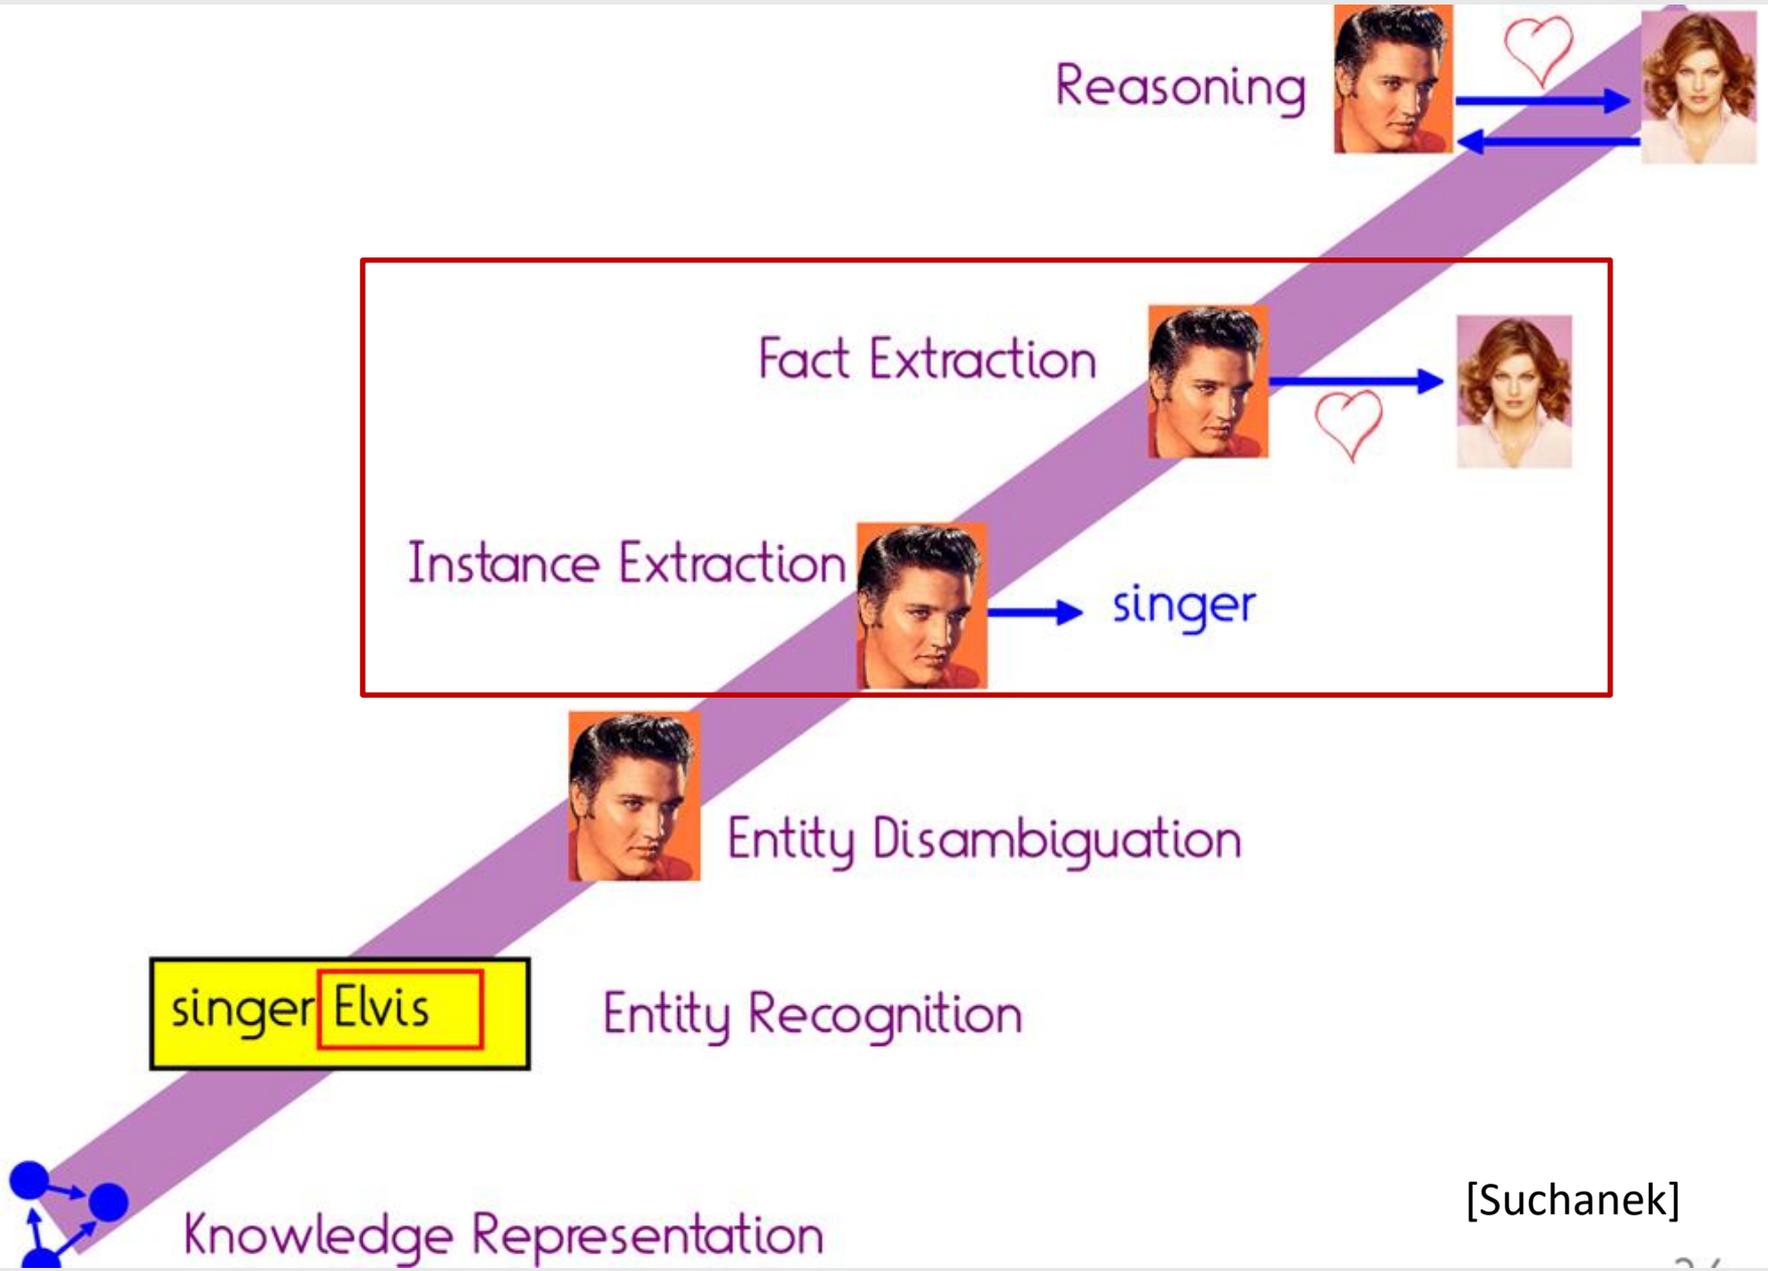
Владелец группы ЕСН Григорий Березкин и шведская инвесткомпания Kinnevik оказались не единственными учредителями московской версии Metro — самой популярной ежедневной газеты в стране. Совладельцами этого бизнеса стали наследник основателя "Балтийской медиагруппы" Олега Руднова Сергей и сын экс-гендиректора ЕСН Михаила Верозуба Владимир. Сейчас бизнес газеты реструктурируется, чтобы соответствовать требованиям закона "О СМИ".

Шведская Kinnevik вместе с родственниками и партнерами Григория Березкина учредила ООО "Газета номер один", следует из данных ЕГРЮЛ. 40,4% в этой компании получила сестра бизнесмена Ольга Березкина, 18,5% — его дочь Анна Тюшкевич, 1% — Kinnevik, 15% — сын бывшего гендиректора ЕСН Михаила Верозуба Владимир и 25,1% — ООО "Волна", контролирующееся структурами Сергея Руднова.

На ООО "Газета номер один" будет переведено управление газетой "Metro Москва", что связано с исполнением требований закона "О СМИ", пояснила "Ъ" представитель ЕСН Марианна Белоусова. Подробности она не уточнила, отметив, что существенных акционерных изменений в газете нет. В самой газете отказались комментировать эту информацию. Свидетельство о СМИ "Газета Metro Москва" до сих пор оформлено на старую структуру — АО "Газета "Метро"", следует из реестра Роскомнадзора. В ЕГРЮЛ актуальные акционеры этой компании недоступны. Ранее по 9,5% в газете принадлежало департаменту имущества Москвы и ГУП "Московский метрополитен". В пресс-службе ГУП сообщили, что предприятие сохраняет долю в газете. Представитель департамента городского имущества и представитель департамента рекламы и СМИ Москвы говорят, что сейчас на балансе города акций газеты нет.

Automated Content Extraction (ACE)





[Suchanek]

Методы

- Шаблоны
- Классификация «с учителем» (supervised)
- С частичным привлечением учителя (semi-supervised) и без учителя (unsupervised)
 - bootstrapping
(использование затравки – seeds)
 - «удаленное обучение»
(distant supervision)
 - обучение без учителя

Выделение гиперонимов (Hearst, 1992)

Pattern	Example
X and other Y	...temples, treasuries, and other important civic buildings.
X or other Y	Bruises, wounds, broken bones or other injuries...
Y such as X	The bow lute, such as the Bambara ndang...
Such Y as X	... such authors as Herrick, Goldsmith, and Shakespeare.
Y including X	...common-law countries, including Canada and England...
Y , especially X	European countries, especially France, England, and Spain...

Словарные определения

Э́лвис Аро́н Прэ́сли (англ. *Elvis Aron Presley*^[3]; 8 января 1935, Тупело — 17 августа 1977, Мемфис) — американский певец и актёр, один из самых коммерчески успешных исполнителей популярной музыки XX века^[4]. В Америке Пресли прозвали «королём рок-н-ролла» (или просто «королём» — *The King*). Он популяризовал рок-н-ролл, хотя не был первым исполнителем этого жанра. Тем не менее, именно он соединил кантри и блюз, дав рождение рокабилли^[4], которым отмечены его первые записи на Sun Records в середине 1950-х гг. Вкрапывая в свой стиль

Дима Никола́евич Била́н^{[1][2]} (имя при рождении и до июня 2008 года — **Ви́ктор Никола́евич Бела́н**; род. 24 декабря 1981, пос. Московский, часть города Усть-Джегута^[2], Карачаево-Черкесская АО, РСФСР, СССР) — российский певец и киноактёр. В июне 2008 года принял данный псевдоним в качестве настоящего имени и фамилии^[3]. Заслуженный артист Кабардино-Балкарии (2006), Заслуженный артист Чечни (2007), Заслуженный артист Ингушетии (2007) и Народный артист Кабардино-Балкарии (2008).

Правила + NEs

PERSON (f) вышла замуж за PERSON (m)

PERSON (m) женился на PERSON (f)

директор ORG PERSON

PERSON назначен директором ORG

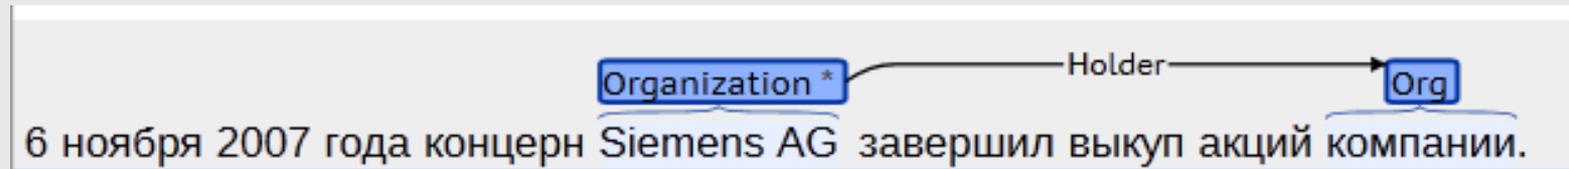
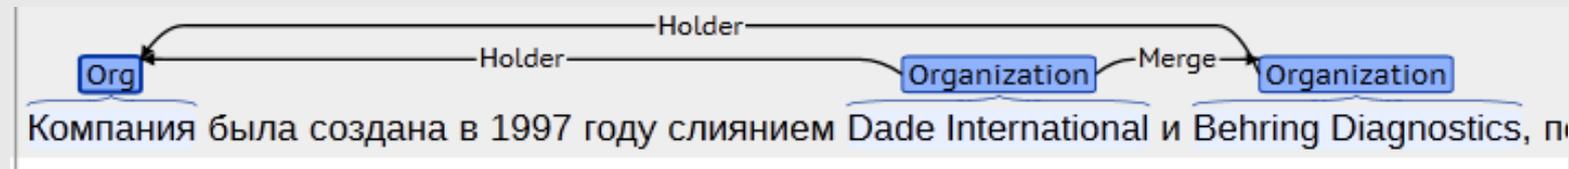
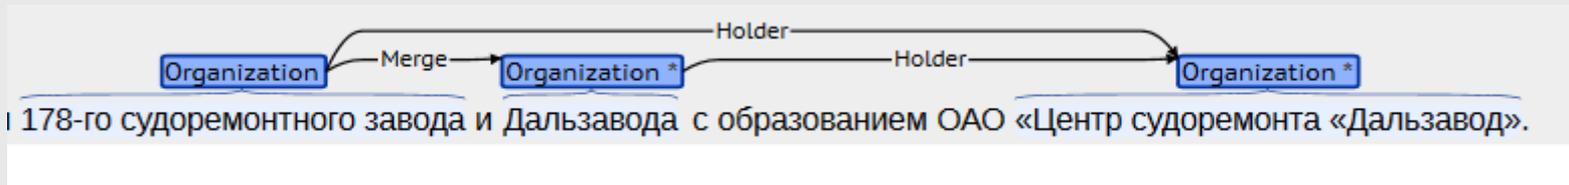
Правила, составленные вручную

- +
 - высокая точность
 - специализация
- –
 - низкая полнота
 - много ручной работы
 - плохая переносимость

Машинное обучение

- Разметить данные (NEs, отношения)
- Разработать набор признаков
- Обучить классификатор
- Оценить качество

Разметка



<http://brat.nlplab.org/>

American Airlines, a unit of AMR, immediately matched the move, spokesman **Tim Wagner** said.

Entity-based features

Entity ₁ type	ORG
Entity ₁ head	<i>airlines</i>
Entity ₂ type	PERS
Entity ₂ head	<i>Wagner</i>
Concatenated types	ORGPERS

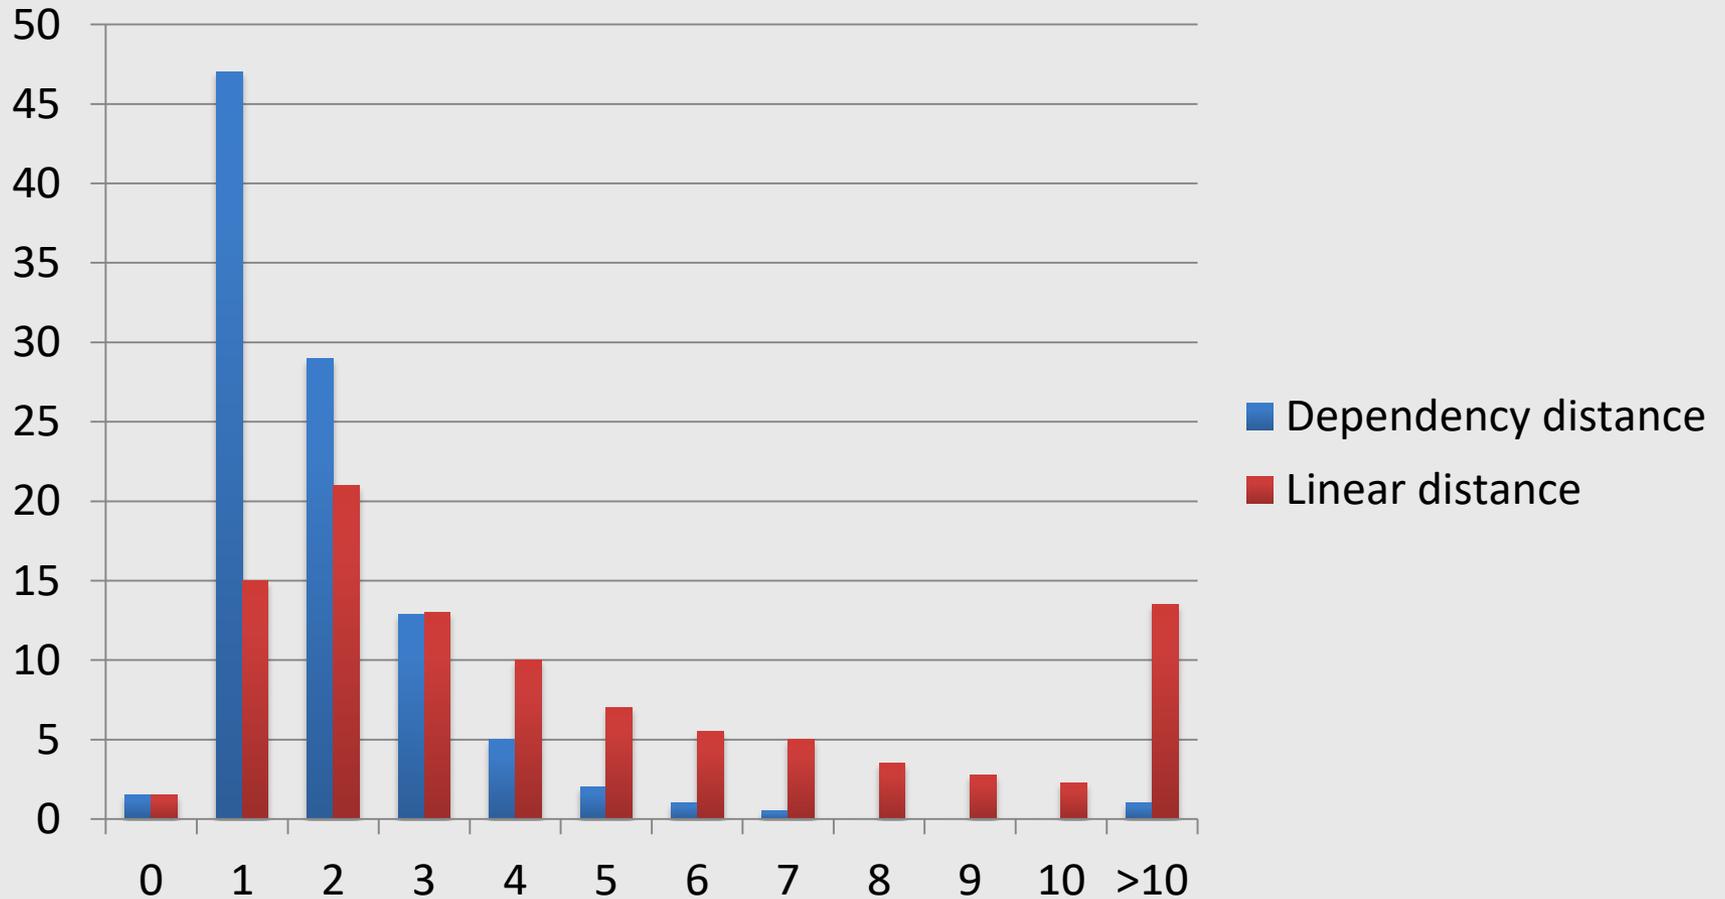
Word-based features

Between-entity bag of words	{ <i>a, unit, of, AMR, Inc., immediately, matched, the, move, spokesman</i> }
Word(s) before Entity ₁	NONE
Word(s) after Entity ₂	<i>said</i>

Syntactic features

Constituent path	$NP \uparrow NP \uparrow S \uparrow S \downarrow NP$
Base syntactic chunk path	$NP \rightarrow NP \rightarrow PP \rightarrow NP \rightarrow VP \rightarrow NP \rightarrow NP$
Typed-dependency path	$Airlines \leftarrow_{subj} matched \leftarrow_{comp} said \rightarrow_{subj} Wagner$

BioNLP 2009/2011 relation extraction



[Björne et al. 2009]

[Chris Manning]

Автоматическая разметка

Avianova (Russia)

From Wikipedia, the free encyclopedia

This article is about a defunct Russian low cost airline. For other uses, see Avianova.

Avianova, LLC (Russian: ООО «Авианова») was a low cost airline based in Moscow, Russia. From its hub at Sheremetyevo International Airport, the carrier served a number of destinations within Russia, as well as an international destination within Ukraine.

Contents [hide]

- History
 - Shareholder coup and bankruptcy
- Destinations
 - Terminated Before Ceasing Operations
- Fleet
- References
- External links

Subsidiary

History [edit]

The company was first registered in 2006.^[1] It received Russian regulatory approval in August 2009;^[citation needed] operations began on 27 August that year.^[2] In the beginning, the company advertised their base fares for RUB 250 (less than USD 10, excluding taxes and fees).^[3] Andrew Pyne, CEO,^[4] voiced the strategy of the new company as "flying those Russians who haven't even seen the inside of an airplane in the past twenty years".^[5]

As of October 2011, Alfa Group controlled 51% of the stake, while US investment company Indigo Partners held the balance.^[6]

Avianova
Авианова



IATA AO	ICAO NET ^[1]	Callsign NOVA
Founded	2009	
Commenced operations	27 August 2009	
Ceased operations	10 October 2011	
Operating bases	Sheremetyevo International Airport	
Secondary hubs	Krasnodar	
Fleet size	6	
Destinations	22	
Parent company	Alfa Group (51%)	
Headquarters	Moscow, Russia	
Key people	Andrew Pyne (CEO) Vladimir Gorbunov (General Director)	

Bootstrapping / затравка (seeds)

- Начинаем с небольшого набора образцов отношений или высокоточного шаблона
СУПРУГИ (Александр Пушкин, Наталья Гончарова)
- Находим упоминания, генерируем шаблоны, повторяем

Примеры

8 декабря 1863 года умерла *Наталья Гончарова, супруга Александра Сергеевича Пушкина.*

...из-за конфликтов с будущей тёщей и отсутствия денег с обеих сторон *пожениться Гончарова и Пушкин* смогли лишь спустя три года.

В 1831 году *Пушкин женится на красавице Н. Н. Гончаровой...*

Гончарова вышла замуж за Пушкина 19-ти лет; поэту было тогда 32 года.

2 марта 1831 года, в Москве, в церкви Большого Вознесения на Большой Никитской, был *совершен обряд венчания А.С. Пушкина с Н.Н. Гончаровой.*

«Удаленное обучение»

- bootstrapping + обучение с учителем
 - очень много примеров отношений
 - большое количество признаков
 - построение классификатора
- «обучение с учителем»
 - классификатор с большим набором признаков
 - обучающая информация в виде примеров
 - не требует итеративного расширения шаблонов
- «обучение без учителя»
 - использует большие коллекции неразмеченных данных
 - лучше справляется с жанровым разнообразием

Snow, Jurafsky, Ng. 2005. Learning syntactic patterns for automatic hypernym discovery. NIPS 17

Fei Wu and Daniel S. Weld. 2007. Autonomously Semantifying Wikipedia. CIKM 2007

Mintz, Bills, Snow, Jurafsky. 2009. Distant supervision for relation extraction without labeled data. ACL09

«Удаленное обучение»

1. Отношения

Born-In

2. Примеры в базе

<Edwin Hubble, Marshfield>

<Albert Einstein, Ulm>

3. Предложения с обоими участниками

Hubble was born in Marshfield

Einstein, born (1879), Ulm

Hubble's birthplace in Marshfield

4. Частотные признаки
(синтаксические
отношения, слова, ...)

PER was born in LOC

PER, born (XXXX), LOC

PER's birthplace in LOC

5. Классификатор на
основе тысяч шаблонов

$P(\text{born-in} \mid f_1, f_2, f_3, \dots, f_{70000})$

Извлечение «без учителя»

Идея: извлечь все отношения из большого корпуса

1. На основе размеченных данных строится классификатор для троек (*trustworthiness*)
2. Извлекаются все отношения между именованными словосочетаниями, отфильтровываются «ненадежные»
3. Оценка вероятности отношения на основе избыточности (повторов)

(FCI, specializes in, software development)

(Tesla, invented, coil transformer)



Argument 1:

Relation:

Argument 2:

All

74 answers from 1611 sentences (cached)

[all](#) [disease \(25\)](#) [cause of death \(22\)](#) [risk factor \(14\)](#) [medical condition in fiction \(11\)](#) [icd 9 cm classification \(10\)](#) [misc.](#) [more types ▾](#)

Lung cancer (460)

[Cancer \(280\)](#)

[Heart disease \(113\)](#)

[Chronic obstructive pulmonary disease \(46\)](#)

[Emphysema \(27\)](#)

[Erectile dysfunction \(19\)](#)

[Halitosis \(14\)](#)

[Respiratory disease \(12\)](#)

[Asthma \(9\)](#)

[Bladder cancer \(8\)](#)

[Insomnia \(7\)](#)

[Cough \(7\)](#)

[Myocardial infarction \(6\)](#)

[Cardiovascular disease \(6\)](#)

[Stroke \(5\)](#)

[Chronic bronchitis \(5\)](#)

Lung cancer

URI:

<http://www.freebase.com/view/m/04p3w>

Types:

- [disease \(Nell\)](#)
- [/medicine/disease \(FreeBase\)](#)
- [/people/cause_of_death \(FreeBase\)](#)
- [/fictional_universe/medical_condition_in_fiction \(FreeBase\)](#)

Extracted Synonyms:

- heart disease and lung cancer
- lung
- his lung cancer
- most lung cancers
- the lung cancer
- lung cancers
- most lung cancer

Extracted from these sentences:

- causes Cigarette smoking causes lung cancer**, heart attacks, strokes, emphysema and other diseases. (via ClueWeb12)
- Cigarette smoking causes lung cancer**, heart disease, emphysema, and other serious diseases in smokers. (via ClueWeb12)
- Cigarette smoke causes lung cancer**, heart disease and a host of other diseases. (via ClueWeb12)
- smoking causes lung cancer**, heart diseases, emphysema, and may complicate relationship. (via ClueWeb12)
- That smoking causes lung cancer**, heart disease, emphysema, and other diseases is universally accepted by medical and scientific authorities. (via ClueWeb12)
- Secondhand smoke causes lung cancer**, other cancer, heart disease and both major

ИНСТРУМЕНТЫ

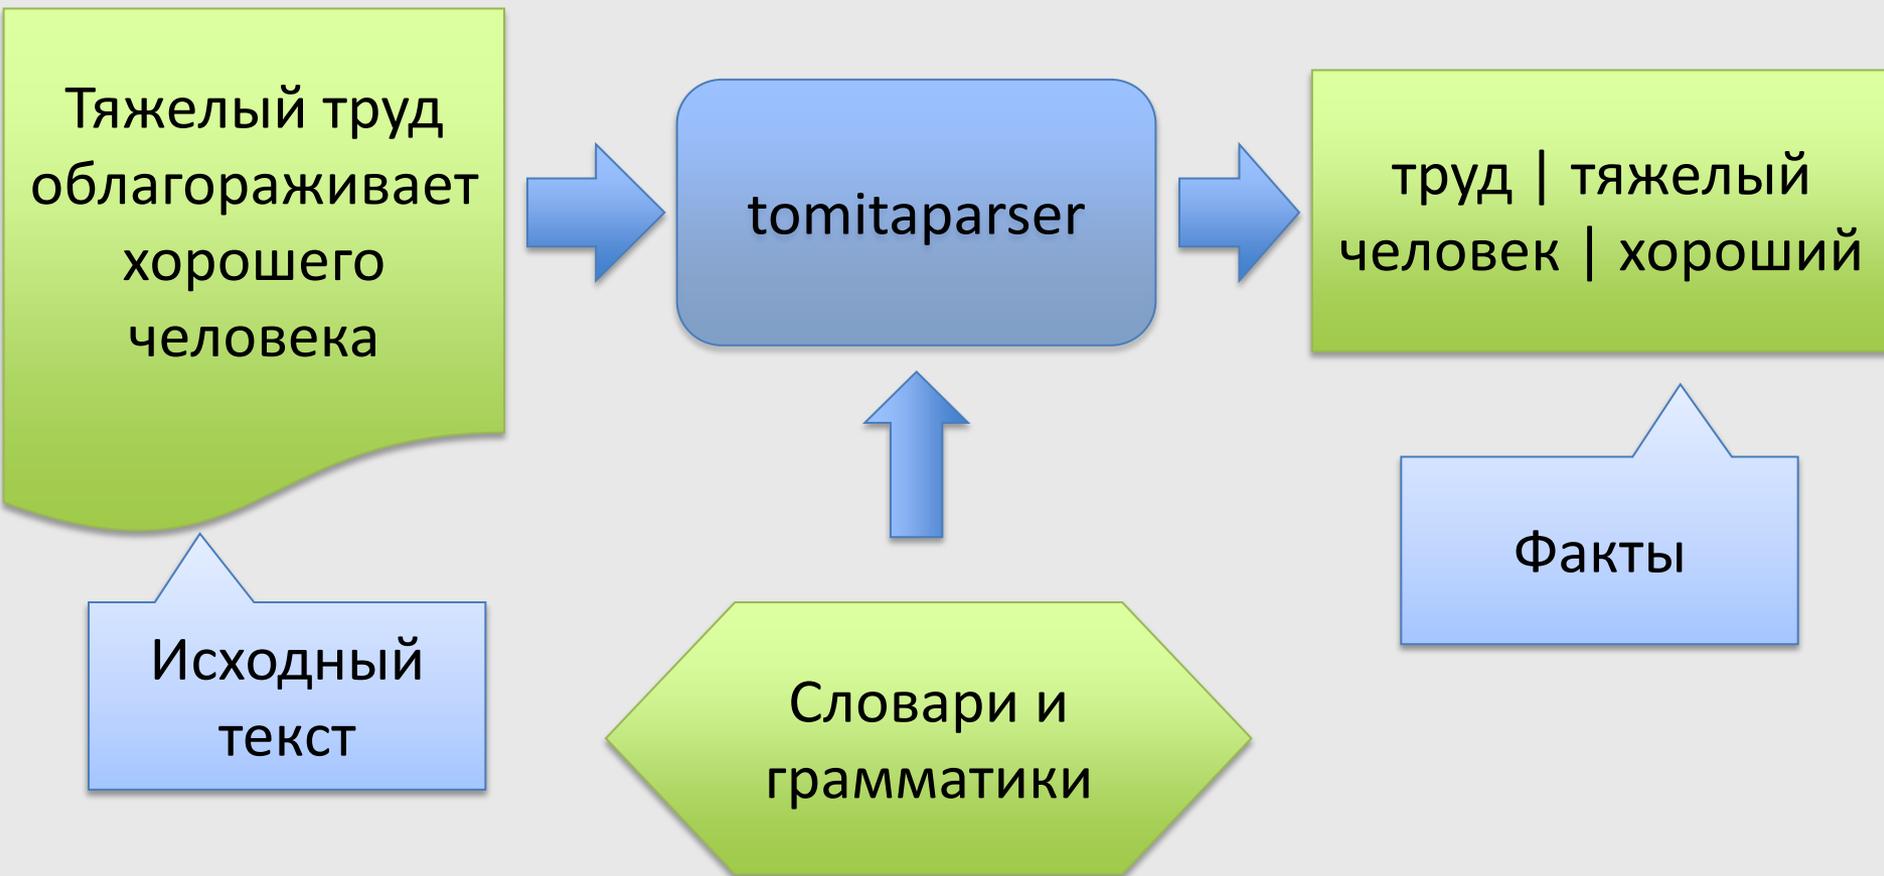
Инструменты

- регулярные выражения
- словари
- классификаторы
- обучение на последовательностях (CRF, НММ)
- обучение правил (Apache UIMA TextRuler)
- инструменты для составления шаблонов (Tomita)

Томи́та-парсер

- Составленные вручную правила
 - контекстно-свободная грамматика
 - $S \rightarrow NP VP$
 - $NP \rightarrow Noun$
 - $NP \rightarrow Adj NP$
- лингвистические признаки (POS, грамеммы, согласование) + словари + регулярные выражения
- алгоритм GLR – парсинга (<http://ru.wikipedia.org/wiki/GLR-парсер>)
- назван в честь японского ученого Масару Томи́та, автора алгоритма
- Используется в Яндексе (Новости, Работа)
- Проект с открытым кодом

Что делает Томита-парсер?



Пример: имена

```
Initial -> Word<wff=/[А-Я]\./>;
```

```
Initials -> Initial Initial;
```

```
Person -> Initials Word<h-reg1>;
```

```
Person -> Word<kwtype=first_names,h-reg1,gnc-agr[1]>
```

```
Word<h-reg1,gnc-agr[1]>;
```

ОЦЕНКА/ДААННЫЕ

Оценка

- Границы/тип

Действующий чемпион мира по шахматам норвежец Магнус Карлсен, который после поражения от россиянина...

- Неоднозначности

Берлин озабочен проблемой беженцев.

Презентация прошла в магазине Библио-Глобус.

Message Understanding Conference (MUC)

<i>Conference</i>	<i>Year</i>	<i>Text Source</i>	<i>Topic (Domain)</i>
MUC-1	1987	Mil. reports	Fleet Operations
MUC-2	1989	Mil. reports	Fleet Operations
MUC-3	1991	News reports	Terrorist activities in Latin America
MUC-4	1992	News reports	Terrorist activities in Latin America
MUC-5	1993	News reports	Corporate Joint Ventures, Microelectronic production
MUC-6	1995	News reports	Negotiation of Labor Disputes and Corporate Management Succession
MUC-7	1997	News reports	Airplane crashes, and Rocket/Missile Launches

Automated Content Extraction (ACE)

ACE 2008

ACE 2008 tasks included Local (within-document) EDR (Entity Detection and Recognition) and RDR (Relation Detection and Recognition) for English and Arabic. ACE 2008 also included a pilot task for Global (cross-document) EDR and RDR for English and Arabic.

- [English Entities V6.6](#)
- [English Relations V6.2](#)
- [Arabic Entities V7.4.2](#)
- [Arabic Relations V6.5](#)
- [Cross-Document Coreference](#)

ACE 2007

Evaluation

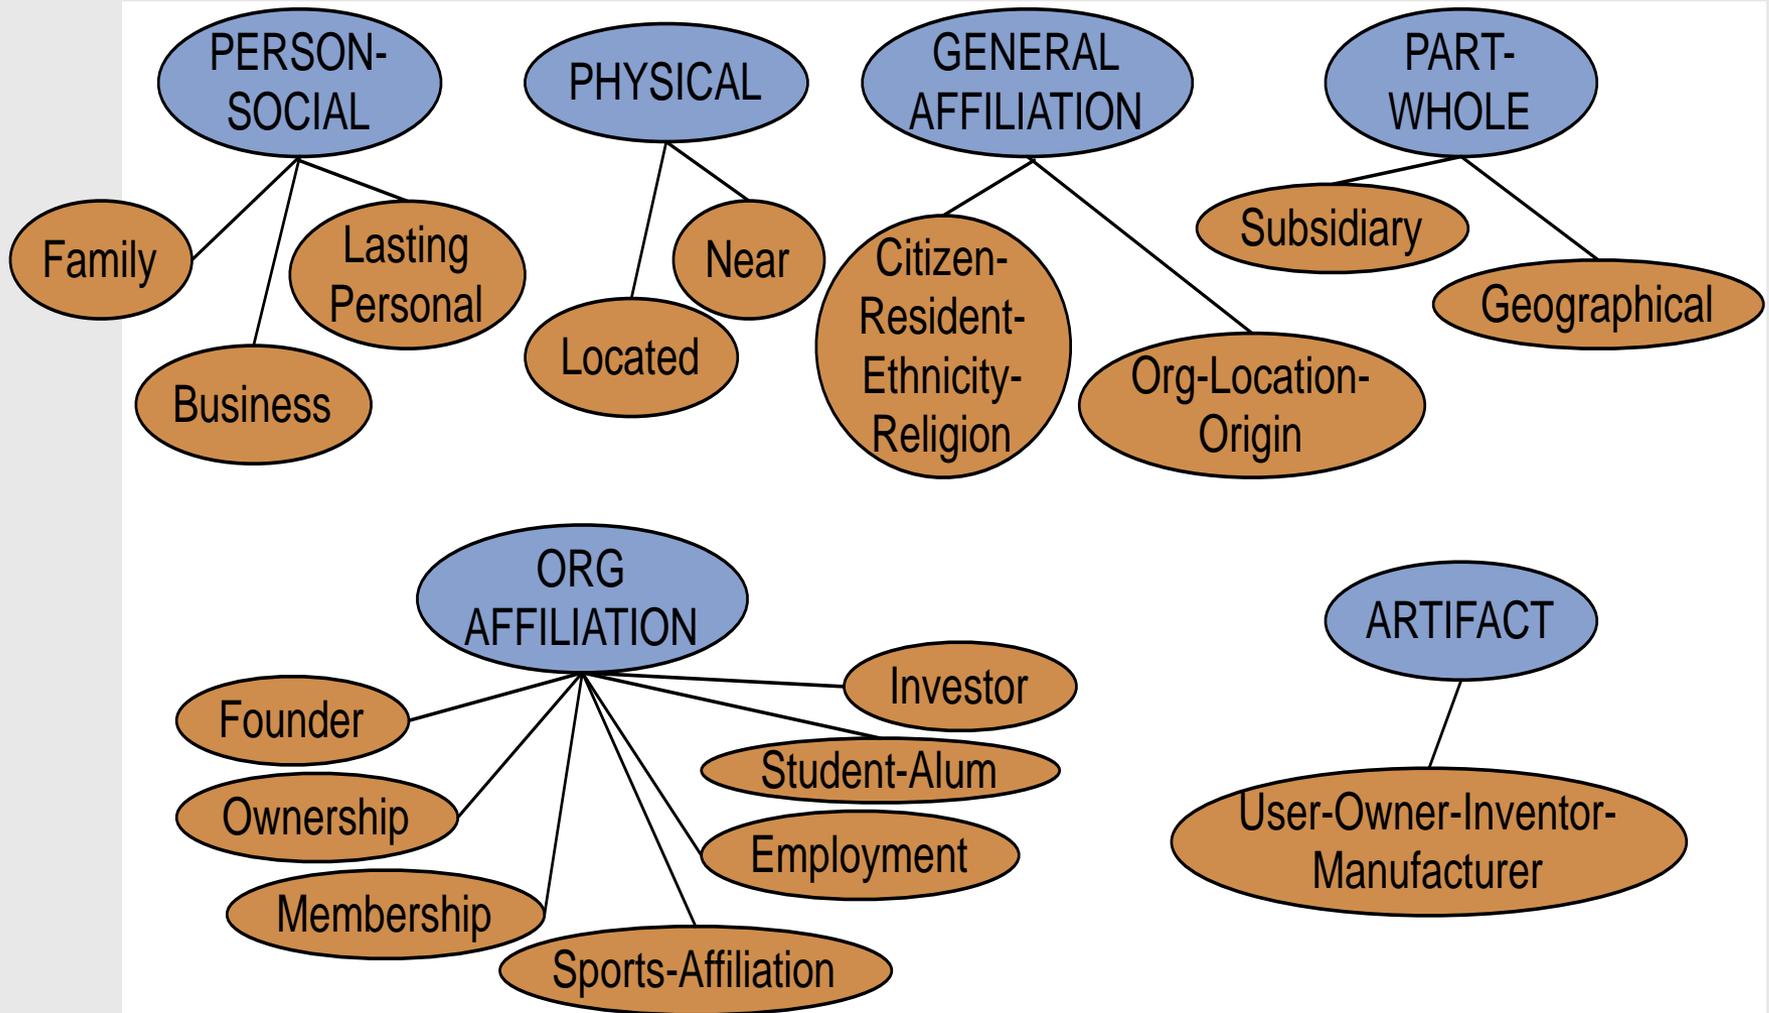
Tasks for ACE 2007 included a pilot evaluation using Spanish data for entity detection and recognition (EDR) and temporal expression recognition and normalization (TERN). Data selection was semi-automatic; a set of candidate documents was manually reviewed to select individual documents that were suitable for ACE annotation, for instance documents that were representative of their genre and contain targeted ACE entity types.

- [Spanish Entities V1.6](#)

Entity Translation Pilot Evaluation

A pilot evaluation of Entity Translation was also conducted as part of ACE 2007. Systems participating in the pilot ET task were evaluated on their ability to take in a text document in one

Automated Content Extraction (ACE)



Text Analysis Conference (TAC)

TAC Track Home Pages									
All Tracks	2008	2009	2010	2011	2012	2013	2014	2015	2016
Question Answering	2008								
Recognizing Textual Entailment	2008	2009	2010	2011					
Summarization	2008	2009	2010	2011			2014		
Knowledge Base Population		2009	2010	2011	2012	2013	2014	2015	2016

РОМИП

- 2004:
 - по описанию персоны найти в Веб-коллекции все связанные факты
 - ответ: фрагмент документа + тип факта (опционально)
- 2005:
 - именованные сущности из новостей
 - персона, организация, геообъект, прочее
 - факты:
 - работает (персона, организация)
 - владеет (персона, организация)
 - владеет (организация, организация)

Результаты оценки (2005)

- оценка на основе ответов систем (а не предварительно подготовленный «золотой стандарт»)
- ~400 документов → ~2600 фактов

```
<fact firstText="ОТДЕЛ ГОСУДАРСТВЕННОГО УПРАВЛЕНИЯ ОХРАНОЙ ТРУДА"  
secondText="БАКИН АЛЕКСАНДР" systemLength="318" userLength="2" systemOffset="110"  
userOffset="18" category="employs" entityOffset="83" collectionIdRef="ROMIP-2005-  
News" relevance="vital"/>
```

```
<fact firstText="ГАЗПРОМ" secondText="LIETUVOS DUJOS" systemLength="185"  
userLength="69" systemOffset="50035" userOffset="50058" category="owns"  
entityOffset="33" collectionIdRef="ROMIP-2005-News" relevance="vital"/>
```

```
<fact firstText="РОССИЯ" secondText="Совершаева Любовь" systemLength="77"  
userLength="77" systemOffset="11590" userOffset="11590" category="employs"  
entityOffset="50" collectionIdRef="ROMIP-2005-News" relevance="notrelevant"/>
```

<http://romip.ru/relevance-tables/ru/index.html>

Данные «Связи компаний» (2016)

Источник: русская Википедия, страницы организаций

Отношение: владение

2,150 Holder/ 992 Subsidiary/4,012 Other

Загребская пивоварня

...

Расположена в столице страны Загребе, принадлежат активам международной пивоваренной корпорации StarBev.

T1	Organization	0	20	Загребская пивоварня
T2	Organization	233	240	StarBev
N1	Reference	T1	wiki:4114742	Загребская пивоварня
N2	Reference	T2	wiki:4114777	StarBev
A1	IsLink	T2		
A2	TypeRel	T2	Holder	

Диалог 2016

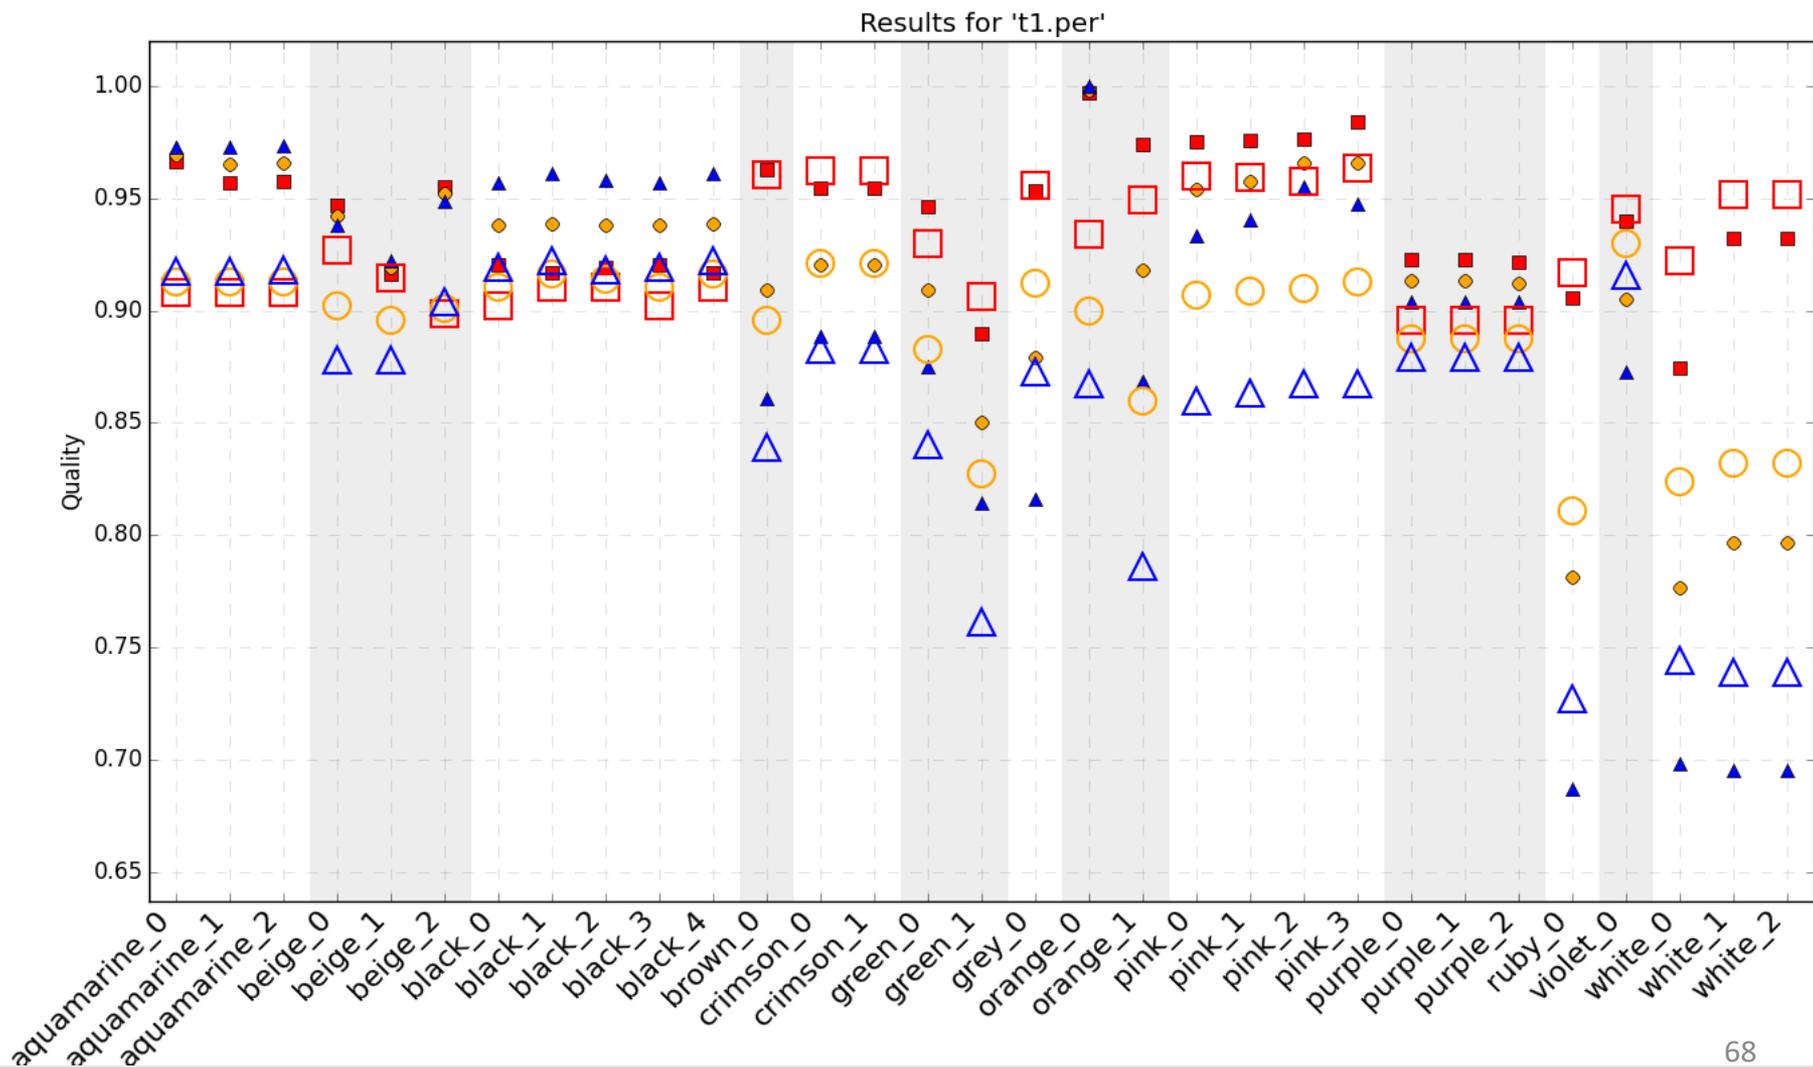
- Именованные сущности:
 - Персоны
 - Организации
 - Локации
- Именованные сущности: атрибуты, нормализация, идентификация
- Факты (отношения)
 - Работает (персона, организация)
 - Сделка (участник1, участник2, ...)
 - Владеет (персона, организация)
 - Встреча(персона1, персона2, ...)

Данные

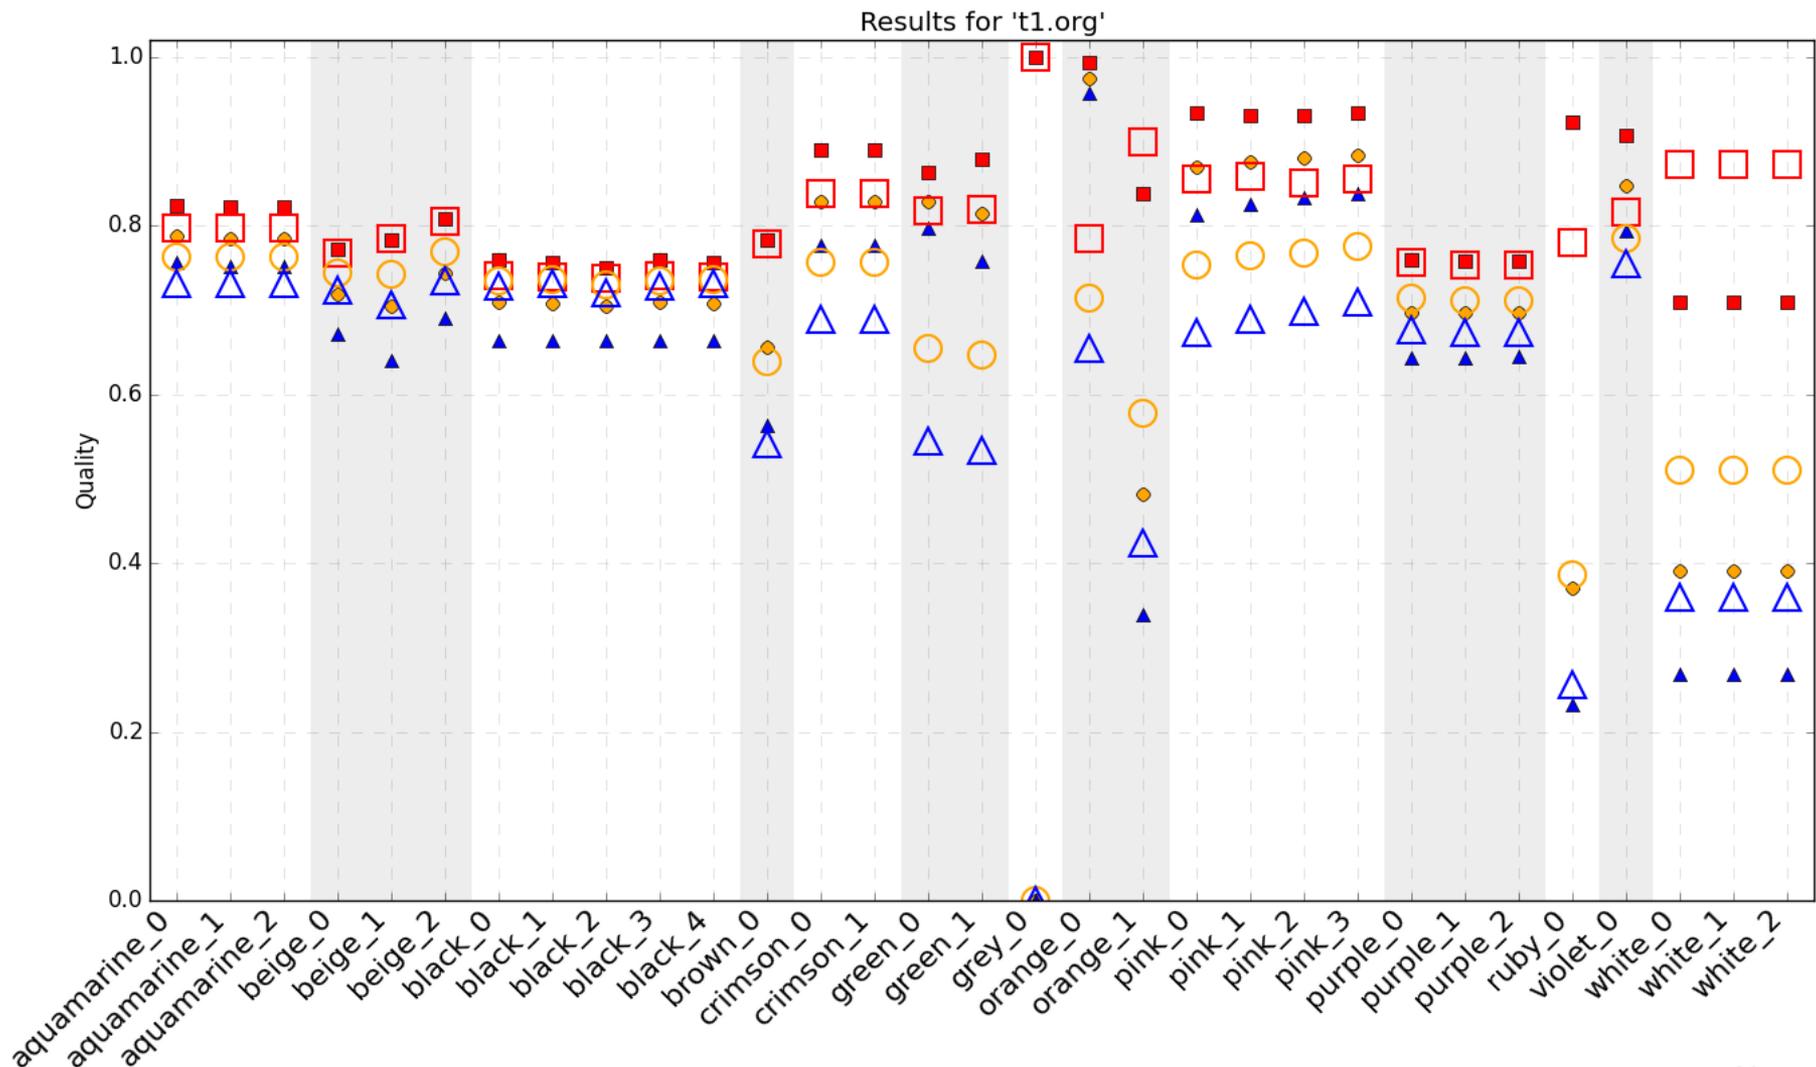
- ~250 новостных сообщений (демо/тест)
- 13 участников
- объем разметки:

Objects	
Demo	Test
2,611	5,019
Facts	
Demo	Test
273	786

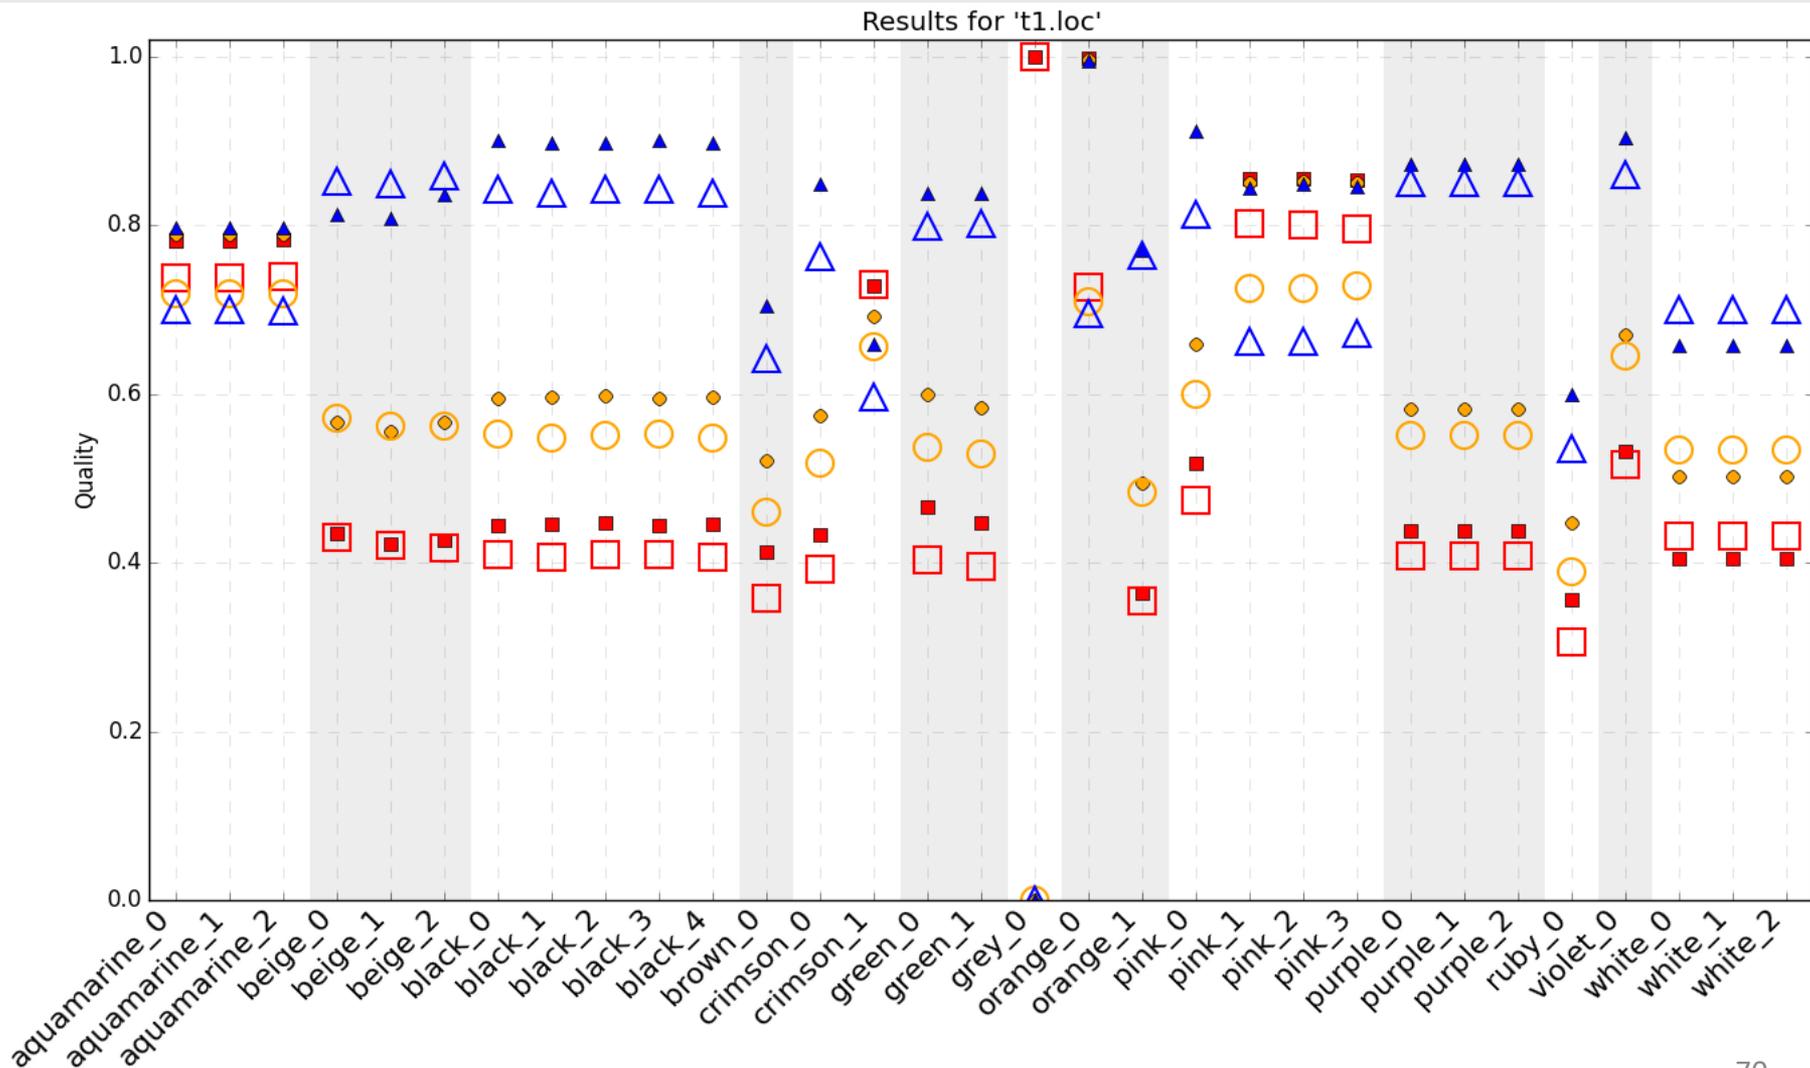
Выделение персон



Выделение организаций



Выделение локаций



Выделение фактов

