

Морфологический анализатор
DIRETRA:
больше, чем глосса


Алёна Аксёнова, Марина Ермолаева

25 октября 2014

The Zen of Diretra

- Diretra – подстрочник с морфологией.
- Diretra ≠ переводчик.
- Лингвистические обобщения – наши друзья.
- Если это возможно, это нужно учесть.
- Сперва общее, затем частное.
- Ошибки недопустимы.
- Простота – одно из лучших качеств человека © Конфуций
... и программы.

Схема работы



Анализ

- Морфологический парсер выполняет анализ (глоссирование) исходной словоформы Языка 1;
- На выходе – все возможные варианты разбора словоформы.

- ВХОД:

evlerimizdeymişler

- ВЫХОД:

ev-ler-imiz-de-ymiş-ler

house-PL-P1PL-LOC-COP.EV-3PL

Разметка соответствий

- Каждому допустимому морфологическому разбору словоформы для Языка 1 ставится в соответствие глосса для Языка 2
- Глоссы могут означать как морфологическую, так и синтаксическую единицу.

- ВХОД:

house-PL-P1PL-LOC-COP.EV-3PL

- ВЫХОД:

3PL-COP.EV-LOC-P1PL-house-PL

Синтез

- Синтезируется словоформа на Языке 2, соответствующая ИСХОДНОЙ.

- ВХОД:

3PL-COP.EV-LOC-P1PL-house-PL

- ВЫХОД:

they.apparently.in.our.houses

Turkish Challenges: фонология

- Гармония гласных:
 - палатальная
 - губная
- Отсутствие гармонии:
 - внутри основ и сложных слов
 - в ряде заимствованных слов с заднерядным гласным последнего слога.

baş-**ın** kol-**un**
голова-P2SG рука-P2SG

ev-**in** göz-**ün**
дом-P2SG глаз-P2SG

hal-**in**
состояние-P2SG

Turkish Challenges: фонология

- Варианты аффиксов:

- звонкий/глухой
- гласный/согласный

oda-**da**

комната-ЛОС

sokak-**ta**

улица-ЛОС

ev-**i**

дом-Р3SG

elbise-**si**

платье-Р3SG

Turkish Challenges: изменения в корнях

- Несколько классов основ с особыми свойствами:
 - озвончение
 - чередование гласного с нулем
 - удвоение согласного

dolar
шкаф

dolab-a
шкаф-DAT

şehir
город

şehir-i
город-ACC

hak-lar
право-PL

hakk-ın
право-P2SG

Turkish Challenges: именная морфология

- Основные морфологические категории имени:

- число;
- посессивность;
- падеж.

STEM	NUM	POSS	CASE
çocuk	-lar	-ın	-a
ребенок	-PL	-P2SG	-DAT
	<i>твоим</i>	<i>детям</i>	

Turkish Challenges: именная морфология

- Суффикс -ki присоединяется к именам в генитиве или локативе;
- Формы на -ki могут затем принимать именные суффиксы;
- LOC-ki и GEN-ki имеют разные свойства (Nankamer 2004);
- Цикличность: -ki может присоединяться к локативным и генитивным формам, уже содержащим -ki.

raf-ta-ki

полка-LOC-KI1

тот, что находится на полке

Hasan-ın-ki

Хасан-GEN-KI2

тот, что принадлежит Хасану

ev-de-ki-ler-in-ki

дом-LOC-KI1-PL-GEN-KI2

тот, что принадлежит тем, что находятся в доме

Turkish Challenges: глагольная морфология

- Именные словоформы могут образовывать:

- предикаты, присоединяя связки и глагольные лично-числовые показатели;
- адвербиальные формы, присоединяя соответствующие суффиксы.

STEM	NUM	POSS	CASE	COPULA	PERS+NUM
ev	-ler	-imiz	-de	-ymiş	-ler
дом	-PL	-P1PL-LOC	-COP.EV		-3PL

По-видимому, они (были) в наших домах.

STEM	CASE	ADV
sokak	-ta	-yken
улица	-LOC	-while

будучи на улице

Turkish Challenges: СЛОЖНЫЕ СЛОВА

- Композиты – сложные слова, образованные соположением основ;
- В турецком языке композиты вида «N+N» или «Adj+N» очень продуктивны;
- Список композитов, пишущихся слитно, открыт.

kız-arkadaş
девушка-друг
(любимая) девушка

sarı-humma
желтый-лихорадка
желтая лихорадка

Парсер: задачи

- Возможность адаптации для работы с разными языками;
- Хорошие результаты при ограниченных ресурсах:
 - анализ морфологии при неизвестной основе
- Обработка сложных случаев:
 - основы с особыми свойствами
 - рекурсивные показатели (-ki)
 - КОМПОЗИТЫ

Парсер: подходы

- Словарь корней и словарь суффиксов:
 - неагглютинативные языки
 - конечный список возможных суффиксов
 - Segalovich 2003
- Конечные автоматы:
 - ПОДХОДЯТ ДЛЯ АГГЛЮТИНАТИВНЫХ ЯЗЫКОВ
 - набор возможных суффиксов бесконечен
 - Hankamer 1986, Eryiğit & Adalı 2004, Sak et al. 2009, Çöltekin 2010, Şahin et al. 2013...

Парсер: описание

- За основную единицу принимается слот – часть цепочки аффиксов, внутри которой порядок следования морфем жестко фиксирован;
- Для каждого слота описываются последовательности категорий, которые могут его заполнять:

Категория	Последовательности	Слот
Число	-NUM-POSS-CASE	Именное словоизменение
Посессивность		
Падеж		
Вопросительная клитика	-(Q)-COP.PRS-PERS	Глагольное словоизменение
Связка	-(Q)-COP.PST-PERS	
Лично-числовые суффиксы	-ADV	
Адвербиальные суффиксы	...	

Парсер: описание

- Набор слотов фиксирован, но...
- Количество и порядок следования категорий внутри слота можно легко изменить.

№	Категория	№	Слот
1	Основа	1	Основа-модификатор
		2	Основа
2	Число	3	Именное словоизменение
3	Посессивность		
4	Падеж		
5	Показатель -ki	4	«Петля» в именном словоименении
6	Вопросительная клитика	5	Глагольное словоизменение
7	Связка		
8	Лично-числовые суффиксы		
9	Адвербиальные суффиксы		

Парсер: данные о языке

- Набор последовательностей категорий для каждого слота;
- Данные о фонологии: инвентарь фонем, описание гармонии гласных;
- Список аффиксов:
 - в список вносятся все алломорфы с ярлыками
 - для каждого алломорфа указывается набор (мор)фонологических ограничений, если они есть
- Словарь основ (опционально)


Парсер: представление данных

- Для каждого слота строятся все возможные цепочки аффиксов;
- Используется информация о порядке следования категорий в слоте, гармонии и ограничениях на контекст.

Цепочка аффиксов	Глосса	Ограничения
-∅-∅-da	-SG-NPS-LOC	после гласных, звонких согласных
-∅-∅-de	-SG-NPS-LOC	после гласных, звонких согласных
-∅-n-da	-SG-P2SG-LOC	после гласных
-∅-n-de	-SG-P2SG-LOC	после гласных
-lar-∅-da	-PL-NPS-LOC	
-ler-∅-de	-PL-NPS-LOC	
-∅-1n-da	-SG-P2SG-LOC	после согласных
-∅-un-da	-SG-P2SG-LOC	после согласных


Парсер: представление данных

- Списки последовательностей преобразуются в буквенные деревья;
- Цепочки аффиксов хранятся в обратном порядке.




Парсер: представление данных

- Аналогичные деревья строятся для лексикона;
- Основы с несколькими фонологическими вариантами рассматриваются как отдельные вхождения.



Парсер: алгоритм анализа

- Переходы между слотами осуществляются с помощью конечного автомата, в котором каждый переход соответствует одному слоту.



Парсер: алгоритм анализа

- Двигаясь справа налево, найти все возможные цепочки аффиксов, которые могут соответствовать словоформе на входе;
- Для каждого гипотетического разбора попытаться найти основу в словаре, которая бы соответствовала неотгlossированной части;
- Если основа нашлась и «лишних» символов не осталось: выдать все такие разборы;
- Если основа нашлась, но слева остались неразобранные символы: попытаться найти в словаре соответствующую им основу; выдать все разборы со сложной основой;
- Если ни для одного разбора не удастся найти простую или сложную основу: выдать все гипотетические разборы.

Парсер: примеры

- Вход: *adamd₁*
 - Гипотетическая основа:
 - *adam* «человек»: найдено
 - *ada* «остров»: найдено
 - *adamd*: не найдено
 - Решение: простая основа
- Результат:
adam-∅-∅-∅-_{d1}-∅
man-SG-NPS-NOM-COP.PST-3

ada-∅-_m-∅-_{d1}-∅
island-SG-P1SG-NOM-COP.PST-3

Парсер: примеры

- Вход: *kızarkadaş*
- Гипотетическая основа:
 - *kızarkadaş*
 - *adaş* «тезка»: найдено
 - *kızark*: не найдено
 - *arkadaş* «друг»: найдено
 - *kız* «девушка»: найдено
- Решение: сложная основа

- Результат:

kız-arkadas-∅-∅-∅

girl-friend-SG-NPS-NOM

kız-arkadas-∅-∅-∅-∅-∅

girl-friend-SG-NPS-NOM-COP.PRS-3

Парсер: примеры

- Вход: *fefe*

- Гипотетическая основа:

- *fefe*: не найдено
- *fef*: не найдено

- Решение: неизвестная основа

- Результат:

fef-∅-∅-*e*

FEF-SG-NPS-DAT

fef-∅-∅-*e*-∅-∅

FEF-SG-NPS-DAT-COP.PRS-3

fefe-∅-∅-∅

FEFE-SG-NPS-NOM

fefe-∅-∅-∅-∅-∅

FEFE-SG-NPS-NOM-COP.PRS-3

Разметка соответствий: основная идея

- То, что в одних языках – синтаксис, в других – морфология;
 - Тюркские языки: богатая морфология;
 - Английский язык: бедная морфология.
- The Mirror Principle (Baker 1985):

Morphological derivations must directly reflect syntactic derivations (and vice versa).

Разметка соответствий: основная идея

- Для языка с бедной морфологией мы “отзеркаливаем” последовательность аффиксов языка с богатой морфологией;
- На месте остаются те аффиксы, которые могут быть морфемами в Языке 2 и относятся к основе.

ada-∅-m-∅-∅-lar

island-SG-P1SG-NOM-COP.PRS-3PL

3PL-COP.PRS-NOM-P1SG-island-SG

they.are.my.island

çocuk-lar-∅-ın-ki-ler-∅-∅

child-PL-NPS-GEN-KI2-PL-NPS-NOM

NOM-NPS-PL-KI2-GEN-NPS-child-PL

ones.owned.by.children

Разметка соответствий: вторичное

- Если в Языке 2 есть передвижение вспомогательного глагола при общем вопросе:
- При наличии вопросительного маркера происходит передвижение временных связок в крайнюю левую позицию.

çocuk-lar-∅-∅-mı-∅-yız

child-PL-NPS-NOM-Q-COP.PRS-1PL

COP.PRS-1PL-NOM-NPS-child-PL-Q

are.we.children.?

Синтез: правила порождения

- 5 типов правил:
 - замена (“DAT” → “to”, “ACC” → “the”)
 - контекстная замена (“COP.PRS” → “am” if 1SG, → “is” if 3SG, → “are” elsewhere)
 - порождение с учётом фонологии (“PL” → “ies” if __Cy, → “PL” → “ves” if __f etc.)
 - порождение по списку (“deer” + “PL” → “deer”)
 - статистический подсчёт и замена (“LOC” → “in” or “on” or “at”)

Синтез: правила замены

- “DAT” → “to”
- “GEN” → “of.the” при основе, “by” при KI
- “ACC” → “the” (DOM в тюркских языках, Lyutikova&Pereltsvaig (2013))
- “1SG” → “I”, “1PL” → “we”, ...

arkadaş-∅-∅-1
friend-SG-NPS-ACC
ACC-NPS-friend-SG
the.friend

arkadaş-∅-1m-1
friend-SG-P1SG-ACC
ACC-P1SG-friend-SG
my.friend

Синтез: порождение по списку

- Список неправильных форм множественного числа.

geyik-ler-∅-∅
deer-PL-NPS-NOM
NOM-NPS-deer-PL
deer

eksen-ler-∅-∅
axis-PL-NPS-NOM
NOM-NPS-axis-PL
axes

Синтез: порождение с учетом фонологии

- Используется для образования правильных форм множественного числа.

karı-lar-∅-∅
wife-PL-NPS-NOM
NOM-NPS-wife-PL
wives

sihirbaz-lar-∅-∅
witch-PL-NPS-NOM
NOM-NPS-witch-PL
witches

Синтез: статистический подсчет и замена

- Для каждого английского существительного имеется локативный предлог (in/at/on), который с ним употребляется чаще всего;
- На него заменяется “LOC”.

ev-∅-∅-de p(in) = 0.77774
house-SG-NPS-LOC
LOC-NPS-house-SG
in.house

okul-∅-∅-da p(at) = 0.999994
school-SG-NPS-LOC
LOC-NPS-school-SG
at.school

Введите словоформы для анализа:

evdekilerinki|

evdeki-ler-@-in-ki-@-@-@-@
home-PL-NPS-GEN-KI2-SG-NPS-NOM-COP.PRS-3
3-COP.PRS-NOM-NPS-SG-KI2-GEN-NPS-home-PL
it.is.one.owned.by.homes

ev-@-@-de-ki-ler-@-in-ki-@-@-@
house-SG-NPS-LOC-KI1-PL-NPS-GEN-KI2-SG-NPS-NOM
NOM-NPS-SG-KI2-GEN-NPS-PL-KI1-LOC-NPS-house-SG
one.owned.by.ones.located.in.house

ev-@-@-de-ki-ler-@-in-ki-@-@-@-@
house-SG-NPS-LOC-KI1-PL-NPS-GEN-KI2-SG-NPS-NOM-COP
.PRS-3
3-COP.PRS-NOM-NPS-SG-KI2-GEN-NPS-PL-KI1-LOC-NPS-ho
use-SG
it.is.one.owned.by.ones.located.in.house

ev

- house {A}
- house {N}
- home {N}
- place {N}
- domestic {A}
- household {A}

â | ı | i | ö | ü | ç | ş | ğ

Загрузить Очистить

Вперед

Processing time: 0.082480 seconds. Words processed: 1.

Введите словоформы для анализа:

kızarkadaş

kızarkadaş
kız_arkadaş-@-@-@
girl_friend-SG-NPS-NOM
NOM-NPS-girl_friend-SG
girl_friend
kız_arkadaş-@-@-@-@-@
girl_friend-SG-NPS-NOM-COP.PRS-3
3-COP.PRS-NOM-NPS-girl_friend-SG
it.is.girl_friend

â ı i ö ü ç ş ğ

Загрузить Очистить

Вперед

kız

- girl {N}
- daughter {N}
- female {N}
- bird {N}
- queen {N}
- chicken {N}

Processing time: 0.002409 seconds. Words processed: 1.

Morphological Analyzer

Введите словоформы для анализа:

çocuklarmıyız

çocuklarmıyız

çocuklar-@-@-@-mı-@-yız
issue-SG-NPS-NOM-Q-COP.PRS-1PL
COP.PRS-1PL-NOM-NPS-issue-SG-Q
are.we.issue.?

çocuk-lar-@-@-mı-@-yız
child-PL-NPS-NOM-Q-COP.PRS-1PL
COP.PRS-1PL-NOM-NPS-child-PL-Q
are.we.children.?

â ı i ö ü ç ş ğ

Загрузить

Очистить

Вперед

Processing time: 3.784502 seconds. Words processed: 1.

çocuk

child {N}
kid {N}
son {N}
baby {N}
infant {A}
infant {N}

Перспективы развития

- Вглубь:
 - финитные и нефинитные глагольные формы
 - прочие части речи
 - деривационная морфология
- Вширь:
 - другие тюркские языки
 - другие алтайские языки

Литература

- Baker M. (1985). The Mirror Principle and Morphosyntactic Explanation // Linguistic Inquiry 16. 373-416.
- Çöltekin Ç. (2010). A Freely Available Morphological Analyzer for Turkish. In Nicoletta Calzolari, Khalid Choukri, Bente Maegaard, Joseph Mariani, Jan Odijk, Stelios Piperidis, Mike Rosner & Daniel Tapias, eds., 'LREC', European Language Resources Association.
- Eryiğit G., Adalı E. (2004). An Affix Stripping Morphological Analyzer for Turkish // IASTED International Multi-Conference on Artificial Intelligence and Applications. Innsbruck, Austria, pages 299-304.
- Göksel A., Kerslake C. (2005). Turkish: A Comprehensive Grammar.
- Hankamer J. (1986). Finite state morphology and left-to-right phonology // Proceedings of the Fifth West Coast Conference on Formal Linguistics, Stanford, CA, pages 29-34.

Литература

- Hankamer J. (2004). Why there are two ki's in Turkish // Imer and Dogan, eds., Current Research in Turkish Linguistics, Eastern Mediterranean University Press, 13-25.
- Kornfilt J. (1996). On copular clitic forms in Turkish. ZAS Papers in Linguistics 6, 96-114.
- Kornfilt J. (1997). Turkish. London and New York: Routledge.
- Lewis G. (1967). Turkish Grammar. Oxford: Oxford University Press.
- Lyutikova E., Pereltsvaig A. (2013). Elucidating nominal structure in articleless languages: A case study of Tatar // Proceedings of 39th Berkeley Linguistic Society Meeting. — Berkeley.
- Şahin M., Sulubacak U., Eryiğit G. (2013). Redefinition Of Turkish Morphology Using Flag Diacritics // Proceedings of the Tenth Symposium on Natural Language Processing (SNLP-2013).