

Математические модели в лингвистике

Вычислительная морфология.

Мати Пентус, Александр Пиперски, Алексей Сорокин

МГУ им. М. В. Ломоносова, межфакультетский курс,
осенний семестр 2015–2016 учебного года

Конечные преобразователи

Пусть Σ , Γ — конечные алфавиты.

Определение конечного преобразователя

Конечный преобразователь: кортеж $M = \langle Q, \Sigma, \Gamma, \Delta, q_0, F \rangle$, где

Конечные преобразователи

Пусть Σ , Γ — конечные алфавиты.

Определение конечного преобразователя

Конечный преобразователь: кортеж $M = \langle Q, \Sigma, \Gamma, \Delta, q_0, F \rangle$, где

- Q — конечное множество состояний

Конечные преобразователи

Пусть Σ , Γ — конечные алфавиты.

Определение конечного преобразователя

Конечный преобразователь: кортеж $M = \langle Q, \Sigma, \Gamma, \Delta, q_0, F \rangle$, где

- Q — конечное множество состояний
- $\Delta \subseteq Q \times (\Sigma \cup \{\varepsilon\}) \times (\Gamma \cup \{\varepsilon\}) \times Q$ — конечное множество переходов

Конечные преобразователи

Пусть Σ , Γ — конечные алфавиты.

Определение конечного преобразователя

Конечный преобразователь: кортеж $M = \langle Q, \Sigma, \Gamma, \Delta, q_0, F \rangle$, где

- Q — конечное множество состояний
- $\Delta \subseteq Q \times (\Sigma \cup \{\varepsilon\}) \times (\Gamma \cup \{\varepsilon\}) \times Q$ — конечное множество переходов
- $q_0 \in Q$ — стартовое состояние
- $F \subseteq Q$ — завершающие состояния.

Конечные преобразователи

Пусть Σ , Γ — конечные алфавиты.

Определение конечного преобразователя

Конечный преобразователь: кортеж $M = \langle Q, \Sigma, \Gamma, \Delta, q_0, F \rangle$, где

- Q — конечное множество состояний
- $\Delta \subseteq Q \times (\Sigma \cup \{\varepsilon\}) \times (\Gamma \cup \{\varepsilon\}) \times Q$ — конечное множество переходов
- $q_0 \in Q$ — стартовое состояние
- $F \subseteq Q$ — завершающие состояния.

Конечный преобразователь принимает пары слов $\langle u, v \rangle \in \Sigma^* \times \Gamma^*$, которые являются метками путей из начального состояния в завершающие. Также можно считать, что конечный преобразователь задаёт многозначное отображение из Σ^* в Γ^* .

Свойства конечных преобразователей

Конечные преобразования замкнуты относительно:

- Конкатенации

Свойства конечных преобразователей

Конечные преобразования замкнуты относительно:

- Конкатенации
- Объединения

Свойства конечных преобразователей

Конечные преобразования замкнуты относительно:

- Конкатенации
- Объединения
- Композиции

Свойства конечных преобразователей

Конечные преобразования замкнуты относительно:

- Конкатенации
- Объединения
- Композиции
- Приоритетного объединения ($\cup_p$).

$$(T_1 \cup_p T_2)(u) = \begin{cases} T_1(u), & T_1(u) \neq \emptyset, \\ T_2(u), & T_1(u) = \emptyset. \end{cases}$$

Свойства конечных преобразователей

Конечные преобразования замкнуты относительно:

- Конкатенации
- Объединения
- Композиции
- Приоритетного объединения ($\cup_p$).

$$(T_1 \cup_p T_2)(u) = \begin{cases} T_1(u), & T_1(u) \neq \emptyset, \\ T_2(u), & T_1(u) = \emptyset. \end{cases}$$


- Обращения: $\phi^{-1} = \{\langle y, x \rangle \mid \langle x, y \rangle \in \phi\}$.

Контекстные замены

С помощью конечных преобразователей можно задавать контекстные замены $X \rightarrow Y \parallel U_V$.

Контекстные замены

С помощью конечных преобразователей можно задавать контекстные замены $X \rightarrow Y \parallel U _ V$. Конечный преобразователь для контекстной замены $a \rightarrow b \parallel c _ d$ ($\Sigma = \Gamma = \{a, b, c, d\}$).



“Модельная задача”

Морфологический синтез: множественное число существительного в английском

“Модельная задача”

Морфологический синтез: множественное число существительного в английском

- $cat+N+Pl \Leftrightarrow cats$
- $torch+N+Pl \Leftrightarrow torches$
- $ally+N+Pl \Leftrightarrow allies$
- $play+N+Pl \Leftrightarrow plays$
- $goose+N+Pl \Leftrightarrow geese$
- $formula+N+Pl \Leftrightarrow formulas/formulae$

Решение модельной задачи


Для решения нужны следующие конечные преобразователи:

- A_1 — проверка условия $\Sigma^+(+N)(+Sg|+Pl) (+N, +Sg, +Pl$ — вспомогательные символы)

Решение модельной задачи

Для решения нужны следующие конечные преобразователи:

- A_1 — проверка условия $\Sigma^+(+N)(+Sg|+Pl)$ ($+N$, $+Sg$, $+Pl$ — вспомогательные символы)
- T_{exc} — преобразователь для исключений (фрагмент):



Решение модельной задачи

Для решения нужны следующие конечные преобразователи:

- A_1 — проверка условия $\Sigma^+(+N)(+Sg|+Pl) (+N, +Sg, +Pl$ — вспомогательные символы)
- T_{exc} — преобразователь для исключений (фрагмент):
- T_s : замены $+N+Sg \rightarrow \hat{_}||_ \#$, $+N+Pl \rightarrow \hat{s}||_ \#$ ($\#$ — конец строки, $\hat{_}$ — вспомогательный символ)

Решение модельной задачи

Для решения нужны следующие конечные преобразователи:

- A_1 — проверка условия $\Sigma^+(+N)(+Sg|+Pl) (+N, +Sg, +Pl$ — вспомогательные символы)
- T_{exc} — преобразователь для исключений (фрагмент):
- T_s : замены $+N+Sg \rightarrow \wedge ||_ \#$, $+N+Pl \rightarrow \wedge s ||_ \#$ ($\#$ — конец строки, $\wedge$ — вспомогательный символ)
- T_y : замена $y \rightarrow ie ||_ \wedge s \#$

Решение модельной задачи

Для решения нужны следующие конечные преобразователи:

- A_1 — проверка условия $\Sigma^+(+N)(+Sg|+Pl) (+N, +Sg, +Pl$ — вспомогательные символы)
- T_{exc} — преобразователь для исключений (фрагмент):
- T_s : замены $+N+Sg \rightarrow \wedge ||_ \#$, $+N+Pl \rightarrow \wedge s ||_ \#$ ($\#$ — конец строки, $\wedge$ — вспомогательный символ)
- T_y : замена $y \rightarrow ie ||_ \wedge s \#$
- $A_{exc, sib}$: проверка условия $\Sigma^+ arch \wedge s \#$

Решение модельной задачи

Для решения нужны следующие конечные преобразователи:

- A_1 — проверка условия $\Sigma^+(+N)(+Sg|+Pl) (+N, +Sg, +Pl$ — вспомогательные символы)
- T_{exc} — преобразователь для исключений (фрагмент):
- T_s : замены $+N+Sg \rightarrow \wedge ||_ \#$, $+N+Pl \rightarrow \wedge s ||_ \#$ ($\#$ — конец строки, $\wedge$ — вспомогательный символ)
- T_y : замена $y \rightarrow ie ||_ \wedge s \#$
- $A_{exc, sib}$: проверка условия $\Sigma^+ arch \wedge s \#$
- T_{sib} : замена $\rightarrow e || [s|z|x|sh|ch] _ \wedge s \#$

Решение модельной задачи

Для решения нужны следующие конечные преобразователи:

- A_1 — проверка условия $\Sigma^+(+N)(+Sg|+Pl) (+N, +Sg, +Pl$ — вспомогательные символы)
- T_{exc} — преобразователь для исключений (фрагмент):
- T_s : замены $+N+Sg \rightarrow \wedge ||_ \#$, $+N+Pl \rightarrow \wedge s ||_ \#$ ($\#$ — конец строки, $\wedge$ — вспомогательный символ)
- T_y : замена $y \rightarrow ie ||_ \wedge s \#$
- $A_{exc, sib}$: проверка условия $\Sigma^+ arch \wedge s \#$
- T_{sib} : замена $\rightarrow e || [s|z|x|sh|ch] _ \wedge s \#$
- T_{cl} : очистка $\wedge \rightarrow ||_$

Решение модельной задачи

Для решения нужны следующие конечные преобразователи:

- A_1 — проверка условия $\Sigma^+(+N)(+Sg|+Pl)$ ($+N$, $+Sg$, $+Pl$ — вспомогательные символы)
- T_{exc} — преобразователь для исключений (фрагмент):
- T_s : замены $+N+Sg \rightarrow \wedge ||_ \#$, $+N+Pl \rightarrow \wedge s ||_ \#$ ($\#$ — конец строки, $\wedge$ — вспомогательный символ)
- T_y : замена $y \rightarrow ie ||_ \wedge s \#$
- $A_{exc,sib}$: проверка условия $\Sigma^+ arch \wedge s \#$
- T_{sib} : замена $\rightarrow e || [s|z|x|sh|ch] _ \wedge s \#$
- T_{cl} : очистка $\wedge \rightarrow ||_$
- Общий преобразователь: $A_1 \circ (T_{exc} \cup_p (T_s \circ T_y \circ (A_{exc,sib} \cup_p T_{sib})) \circ T_{cl}))$

Компиляторы для конечных преобразований

- XFST (Xerox finite-state toolkit)
- HFST (Helsinki finite-state toolkit)
- FOMA
- SFST (Stuttgart finite-state toolkit)
- OpenFST

Программа FOMA

- FOMA — программа для компиляции описаний конечных преобразователей в преобразователи.
- Разработана М. Халденом (Mans Hulden) в 2009–2015гг, последняя версия 0.9.18 вышла 12 июня 2015г.

Программа FOMA

- FOMA — программа для компиляции описаний конечных преобразователей в преобразователи.
- Разработана М. Халденом (Mans Hulden) в 2009–2015гг, последняя версия 0.9.18 вышла 12 июня 2015г.
- Программа с открытым кодом, написана на языке C++. Существует библиотека для использования в программах на C++. Написана под linux, допускает использование под Windows.

Программа FOMA

- FOMA — программа для компиляции описаний конечных преобразователей в преобразователи.
- Разработана М. Халденом (Mans Hulden) в 2009–2015гг, последняя версия 0.9.18 вышла 12 июня 2015г.
- Программа с открытым кодом, написана на языке C++. Существует библиотека для использования в программах на C++. Написана под linux, допускает использование под Windows.
- Получает на вход описания преобразований в xfst-формате (Karttunen, 2003) и преобразует их в конечные преобразователи.

Программа FOMA

- FOMA — программа для компиляции описаний конечных преобразователей в преобразователи.
- Разработана М. Халденом (Mans Hulden) в 2009–2015гг, последняя версия 0.9.18 вышла 12 июня 2015г.
- Программа с открытым кодом, написана на языке C++. Существует библиотека для использования в программах на C++. Написана под linux, допускает использование под Windows.
- Получает на вход описания преобразований в xfst-формате (Karttunen, 2003) и преобразует их в конечные преобразователи.
- Также позволяет преобразовывать регулярные выражения в конечные автоматы и выполнять с ними различные операции.
- Сайт: <https://code.google.com/p/foma/>.

Код для модельной задачи

```
### english.foma ###

read lexc irregular.lexc
define IrregularNounPlural;

define Vowel [ a | i | e | o | u | y ];
define Consonant [ b | c | d | f | g | h | j | k | l | m | n | p | q | r | s | t |
    v | w | x | z ];
define Letter [ Vowel | Consonant ];
define Word [ Letter ]+;
define NounMark "+N";
define NounNumber "+Sg" | "+Pl";
define Noun Word NounMark NounNumber;

define NounAffixation "+N" "+Sg" -> "^" || _ .#., "+N" "+Pl" -> "^" s || _ .#.;
define yReplacement y -> i e || Consonant _ "^" s .#.;
define sibException [ Letter ]+ a r c h _ "^" s ;
define Sibilant [ x | s | z | c h | s h ];
define elnsertion [..] -> e || Sibilant _ "^" s .#.;
define checkSibilant [ sibException .P. elnsertion ];
define Cleanup "^" -> [] || _ ;
define RegularNoun [ NounAffixation .o. yReplacement .o. checkSibilant .o. Cleanup
    ] ;
define Grammar Noun .o. [ IrregularNounPlural .P. RegularNoun ] ;

push Grammar
```

Лексикон

- Лексикон (*.lexc) используется для задания конечных регулярных выражений/преобразований.

```
!!! lexicon.lexc !!!  
Multichar_Symbols +N +V +Past +Pres +Part +1 +2 +3  
+Sg +Pl  
  
LEXICON IrregularPlural  
  
goose+N+Pl:geese #;  
mouse+N+Pl:mice #;  
foot+N+Pl:feet #;  
formula+N+Pl:formulas #;  
formula+N+Pl:formulae #;  
cactus+N+Pl:cactuses #;  
cactus+N+Pl:cacti #;
```

Лексикон

- Лексикон (*.lexc) используется для задания конечных регулярных выражений/преобразований.

```
!!! lexicon.lexc !!!  
Multichar_Symbols +N +V +Past +Pres +Part +1 +2 +3  
+Sg +Pl  
  
LEXICON IrregularPlural  
  
goose+N+Pl:geese #;  
mouse+N+Pl:mice #;  
foot+N+Pl:feet #;  
formula+N+Pl:formulas #;  
formula+N+Pl:formulae #;  
cactus+N+Pl:cactuses #;  
cactus+N+Pl:cacti #;
```

- Применяется для запоминания словарей и создания списков исключений, а также задания согласовательных классов.

Лексикон

- Лексикон (*.lexc) используется для задания конечных регулярных выражений/преобразований.

```
!!! lexicon.lexc !!!  
Multichar_Symbols +N +V +Past +Pres +Part +1 +2 +3  
+Sg +Pl  
  
LEXICON IrregularPlural  
  
goose+N+Pl:geese #;  
mouse+N+Pl:mice #;  
foot+N+Pl:feet #;  
formula+N+Pl:formulas #;  
formula+N+Pl:formulae #;  
cactus+N+Pl:cactuses #;  
cactus+N+Pl:cacti #;
```

- Применяется для запоминания словарей и создания списков исключений, а также задания согласовательных классов.
- Также в лексиконе принято задавать мультисимвольные последовательности.

Синтаксис FOMA: регулярные преобразования

- FOMA позволяет задавать регулярные выражения.

Синтаксис FOMA: регулярные преобразования

- FOMA позволяет задавать регулярные выражения.
- В качестве элементарных регулярных выражений используются ASCII-символы, а также сохранённые мультисимвольные последовательности. Например, “+N” считается одним символом.

Синтаксис FOMA: регулярные преобразования

- FOMA позволяет задавать регулярные выражения.
- В качестве элементарных регулярных выражений используются ASCII-символы, а также сохранённые мультисимвольные последовательности. Например, “+N” считается одним символом.
- Рекомендуются разделять перемножаемые регулярные выражения пробелами, чтобы конкатенация не воспринималась как один символ.

Синтаксис FOMA: регулярные преобразования

- FOMA позволяет задавать регулярные выражения.
- В качестве элементарных регулярных выражений используются ASCII-символы, а также сохранённые мультисимвольные последовательности. Например, “+N” считается одним символом.
- Рекомендуются разделять перемножаемые регулярные выражения пробелами, чтобы конкатенация не воспринималась как один символ.
- Регулярные преобразования определяются аналогично регулярным выражениям...

Синтаксис FOMA: регулярные преобразования

- FOMA позволяет задавать регулярные выражения.
- В качестве элементарных регулярных выражений используются ASCII-символы, а также сохранённые мультисимвольные последовательности. Например, “+N” считается одним символом.
- Рекомендуются разделять перемножаемые регулярные выражения пробелами, чтобы конкатенация не воспринималась как один символ.
- Регулярные преобразования определяются аналогично регулярным выражениям...
- Базовые преобразования: контекстные замены.

Операции над регулярными выражениями

Поддерживаются следующие операции над регулярными преобразованиями:

- объединение ($|$),

Операции над регулярными выражениями

Поддерживаются следующие операции над регулярными преобразованиями:

- объединение ($|$),
- конкатенация (задаётся простым приписыванием),

Операции над регулярными выражениями

Поддерживаются следующие операции над регулярными преобразованиями:

- объединение ($|$),
- конкатенация (задаётся простым приписыванием),
- итерация ($*$),
- положительная итерация ($+$),

Операции над регулярными выражениями

Поддерживаются следующие операции над регулярными преобразованиями:

- объединение ($|$),
- конкатенация (задаётся простым приписыванием),
- итерация ($*$),
- положительная итерация ($+$),
- взятие 0 или 1 раз (задаётся взятием в круглые скобки):
(X) соответствует $X|1$ в стандартном синтаксисе,

Операции над регулярными выражениями

Поддерживаются следующие операции над регулярными преобразованиями:

- объединение ($|$),
- конкатенация (задаётся простым приписыванием),
- итерация ($*$),
- положительная итерация ($+$),
- взятие 0 или 1 раз (задаётся взятием в круглые скобки):
(X) соответствует $X|1$ в стандартном синтаксисе,
- вместо круглых скобок — квадратные,

Операции над регулярными выражениями

Поддерживаются следующие операции над регулярными преобразованиями:

- объединение ($|$),
- конкатенация (задаётся простым приписыванием),
- итерация ($*$),
- положительная итерация ($+$),
- взятие 0 или 1 раз (задаётся взятием в круглые скобки):
(X) соответствует $X|1$ в стандартном синтаксисе,
- вместо круглых скобок — квадратные,
- $[]$ или $[..]$ — обозначение для пустого слова.

Регулярные преобразования

- Базовые регулярные преобразования: контекстные замены $X \rightarrow Y || U_V$ записываются в точности в таком виде.
- В качестве X и Y можно брать произвольные регулярные выражения, а также символ начала/конца строки $\#$.

Регулярные преобразования

- Базовые регулярные преобразования: контекстные замены $X \rightarrow Y || U_V$ записываются в точности в таком виде.
- В качестве X и Y можно брать произвольные регулярные выражения, а также символ начала/конца строки $\#.$.
Например, $a \rightarrow b ||_c+. \#.$ означает заменить a на b , если после этого до конца слова встречаются только буквы c , притом в ненулевом количестве.

Регулярные преобразования

- Базовые регулярные преобразования: контекстные замены $X \rightarrow Y || U_V$ записываются в точности в таком виде.
- В качестве X и Y можно брать произвольные регулярные выражения, а также символ начала/конца строки $\#..$.
Например, $a \rightarrow b ||_c+. \#.$ означает заменить a на b , если после этого до конца слова встречаются только буквы c , притом в ненулевом количестве.
- В качестве преобразований также используются регулярные выражения X : такое преобразование действует только на слова из X , отображая их в себя.

Операции над регулярными преобразованиями

- Регулярные преобразования можно сохранять в переменные с помощью команды **define**:

define⟨имя_переменной⟩⟨выражение⟩;

Операции над регулярными преобразованиями

- Регулярные преобразования можно сохранять в переменные с помощью команды **define**:

define⟨имя_переменной⟩⟨выражение⟩;

- Регулярные преобразования можно комбинировать с помощью операций над регулярными выражениями, а также:

Операции над регулярными преобразованиями

- Регулярные преобразования можно сохранять в переменные с помощью команды **define**:

define⟨имя_переменной⟩⟨выражение⟩;

- Регулярные преобразования можно комбинировать с помощью операций над регулярными выражениями, а также:
 - Композиции (*.o.*)

Операции над регулярными преобразованиями

- Регулярные преобразования можно сохранять в переменные с помощью команды **define**:

define⟨имя_переменной⟩⟨выражение⟩;

- Регулярные преобразования можно комбинировать с помощью операций над регулярными выражениями, а также:
 - Композиции (*.o.*)
 - Приоритетного объединения (*.p.*)

FOMA: команды

- Для сохранения промежуточных преобразователей используется стек.

FOMA: команды

- Для сохранения промежуточных преобразователей используется стек.
- Команды для работы со стеком:
 - **source** $\langle \text{имя_файла} \rangle$ — выполнить команды из файла
 - **push** $\langle \text{имя_переменной} \rangle$ — поместить преобразователь, хранящийся в переменной, на вершину стека.

FOMA: команды

- Для сохранения промежуточных преобразователей используется стек.
- Команды для работы со стеком:
 - **source** $\langle \text{имя_файла} \rangle$ — выполнить команды из файла
 - **push** $\langle \text{имя_переменной} \rangle$ — поместить преобразователь, хранящийся в переменной, на вершину стека.
 - **pop** — убрать преобразователь с вершины стека.

FOMA: команды

- Для сохранения промежуточных преобразователей используется стек.
- Команды для работы со стеком:
 - **source** $\langle \text{имя_файла} \rangle$ — выполнить команды из файла
 - **push** $\langle \text{имя_переменной} \rangle$ — поместить преобразователь, хранящийся в переменной, на вершину стека.
 - **pop** — убрать преобразователь с вершины стека.
 - **down** — запустить преобразователь на вершине стека в “прямом” направлении.

FOMA: команды

- Для сохранения промежуточных преобразователей используется стек.
- Команды для работы со стеком:
 - **source** $\langle \text{имя_файла} \rangle$ — выполнить команды из файла
 - **push** $\langle \text{имя_переменной} \rangle$ — поместить преобразователь, хранящийся в переменной, на вершину стека.
 - **pop** — убрать преобразователь с вершины стека.
 - **down** — запустить преобразователь на вершине стека в “прямом” направлении.
 - **up** — запустить преобразователь на вершине стека в “обратном” направлении.

FOMA: команды

- Для сохранения промежуточных преобразователей используется стек.
- Команды для работы со стеком:
 - **source** $\langle \text{имя_файла} \rangle$ — выполнить команды из файла
 - **push** $\langle \text{имя_переменной} \rangle$ — поместить преобразователь, хранящийся в переменной, на вершину стека.
 - **pop** — убрать преобразователь с вершины стека.
 - **down** — запустить преобразователь на вершине стека в “прямом” направлении.
 - **up** — запустить преобразователь на вершине стека в “обратном” направлении.
 - **upper** — напечатать слова, к которым применим преобразователь.
 - **lower** — напечатать слова, которые могут быть результатами работы преобразователя.

Компиляция кода


```
C:\Windows\System32\cmd.exe - foma
Microsoft Windows [Version 6.1.7601]
(c) Корпорация Майкрософт (Microsoft Corp.), 2009. Все права защищены.

d:\alexeu\Преподавание\ОТМП\Спецкурс весна 2015\examples\Morphology>foma
Foma, version 0.9.17alpha
Copyright c 2008-2012 Mans Hulden
This is free software; see the source code for copying conditions.
There is ABSOLUTELY NO WARRANTY; for details, type "help license"

Type "help" to list all commands available.
Type "help <topic>" or help "<operator>" for further help.

foma[0]: source english.foma
Opening file 'english.foma'.
IrregularPlural...?
Building lexicon...
*Warning: no Root lexicon, using 'IrregularPlural' as Root.
Determinizing...
Minimizing...
Done!
940 bytes. 29 states, 34 arcs, 7 paths.
defined IrregularNounPlural: 940 bytes. 29 states, 34 arcs, 7 paths.
defined Vowel: 363 bytes. 2 states, 6 arcs, 6 paths.
defined Consonant: 783 bytes. 2 states, 20 arcs, 20 paths.
defined Letter: 963 bytes. 2 states, 26 arcs, 26 paths.
defined Word: 1.3 kB. 2 states, 52 arcs, Cyclic.
defined NounMark: 183 bytes. 2 states, 1 arc, 1 path.
defined NounNumber: 247 bytes. 2 states, 2 arcs, 2 paths.
defined Noun: 1.4 kB. 4 states, 55 arcs, Cyclic.
defined NounAffixation: 689 bytes. 5 states, 23 arcs, Cyclic.
defined yReplacement: 2.6 kB. 9 states, 130 arcs, Cyclic.
defined sibException: 3.0 kB. 8 states, 158 arcs, Cyclic.
defined $ibilant: 349 bytes. 4 states, 6 arcs, 5 paths.
defined Insertion: 1.2 kB. 9 states, 53 arcs, Cyclic.
defined check$ibilant: 6.4 kB. 16 states, 371 arcs, Cyclic.
defined Cleanup: 276 bytes. 1 state, 2 arcs, Cyclic.
defined RegularNoun: 10.5 kB. 26 states, 631 arcs, Cyclic.
defined Grammar: 14.0 kB. 47 states, 853 arcs, Cyclic.
14.0 kB. 47 states, 853 arcs, Cyclic.
foma[1]: _
```

Примеры использования



```
C:\Windows\System32\cmd.exe - foma
foma[1]: down
apply down> match+N+Pl
matches
apply down> house+N+Pl
houses
apply down> word+N+Pl
words
apply down> valley+N+Pl
valleys
apply down> ally+N+Pl
allies
apply down> arch+N+Pl
arches
apply down> monarch+N+Pl
monarchs
apply down> fox+N+PL
foxes
apply down> fox+N+Pl
foxes
apply down> formula+N+Pl
formulae
formulae
apply down> cactus+N+Pl
cactuses
cacti
apply down> mouse+N+Pl
mice
apply down>
```

Свойства модели с конечным числом состояний

- Хорошо подходит для аддитивной модели словоизменения и агглютинативных языков.

Свойства модели с конечным числом состояний

- Хорошо подходит для аддитивной модели словоизменения и агглютинативных языков.
- Чем дальше морфология от аддитивной модели, тем менее естественна модель с конечным числом состояний.

Свойства модели с конечным числом состояний

- Хорошо подходит для аддитивной модели словоизменения и агглютинативных языков.
- Чем дальше морфология от аддитивной модели, тем менее естественна модель с конечным числом состояний.

Возможные трудности:

- нелокальные явления (гармония гласных и т.д),

Свойства модели с конечным числом состояний

- Хорошо подходит для аддитивной модели словоизменения и агглютинативных языков.
- Чем дальше морфология от аддитивной модели, тем менее естественна модель с конечным числом состояний.

Возможные трудности:

- нелокальные явления (гармония гласных и т.д),
- многочисленность словоизменительных классов,

Свойства модели с конечным числом состояний

- Хорошо подходит для аддитивной модели словоизменения и агглютинативных языков.
- Чем дальше морфология от аддитивной модели, тем менее естественна модель с конечным числом состояний.

Возможные трудности:

- нелокальные явления (гармония гласных и т.д),
- многочисленность словоизменяющих классов,
- неавтоматические чередования, развитая фузия,

Свойства модели с конечным числом состояний

- Хорошо подходит для аддитивной модели словоизменения и агглютинативных языков.
- Чем дальше морфология от аддитивной модели, тем менее естественна модель с конечным числом состояний.

Возможные трудности:

- нелокальные явления (гармония гласных и т.д),
- многочисленность словоизменяющих классов,
- неавтоматические чередования, развитая фузия,
- неконкатенационная морфология (внутренняя флексия, аблаут),

Свойства модели с конечным числом состояний

- Хорошо подходит для аддитивной модели словоизменения и агглютинативных языков.
- Чем дальше морфология от аддитивной модели, тем менее естественна модель с конечным числом состояний.

Возможные трудности:

- нелокальные явления (гармония гласных и т.д),
- многочисленность словоизменяющих классов,
- неавтоматические чередования, развитая фузия,
- неконкатенационная морфология (внутренняя флексия, аблаут),
- редупликация.

Глагольные формы в языке йоулумни

основа	герундий	дуратив
saw “кричать”	saw-inay	sawaa-ʔaa-n
siim “разрушать”	siim-inay	siimii-ʔaa-n
hoyoo “называть”	hoy-inay	hoyoo-ʔaa-n
diiyl “охранять”	diyl-inay	diyiil-ʔaa-n
ʔilk “петь”	ʔilk-inay	ʔiliik-ʔaa-n
hiwiit “гулять”	hiwt-inay	hiwiit-ʔaa-n

Глагольные формы в языке йоулумни

Глагольные формы в языке йоулумни

основа	герундий	дуратив
saw “кричать”	saw-inay	sawaa-ʔaa-n
siim “разрушать”	siim-inay	siimuu-ʔaa-n
hoyoo “называть”	hoy-inay	hoyoo-ʔaa-n
diiyl “охранять”	diyl-inay	diyiil-ʔaa-n
ʔilk “петь”	ʔilk-inay	ʔiliik-ʔaa-n
hiwiit “гулять”	hiwt-inay	hiwiit-ʔaa-n

Глагольные формы в языке йоулумни

Если основа имела вид $\alpha_1 V(V)\alpha_2(V)(V)\alpha_3$, где $\alpha_1, \alpha_2, \in C, \alpha_3 \in C \cup \{\varepsilon\}$, то основа герундия имеет вид $\alpha_1 V\alpha_2\alpha_3$,

Глагольные формы в языке йоулумни

основа	герундий	дуратив
saw “кричать”	saw-inay	sawaa-ʔaa-n
siim “разрушать”	siim-inay	siimuu-ʔaa-n
hoyoo “называть”	hoy-inay	hoyoo-ʔaa-n
diiyl “охранять”	diyl-inay	diyiil-ʔaa-n
ʔilk “петь”	ʔilk-inay	ʔiliik-ʔaa-n
hiwiit “гулять”	hiwt-inay	hiwiit-ʔaa-n

Глагольные формы в языке йоулумни


Если основа имела вид $\alpha_1 V(V)\alpha_2(V)(V)\alpha_3$, где $\alpha_1, \alpha_2, \in C, \alpha_3 \in C \cup \{\varepsilon\}$, то основа герундия имеет вид $\alpha_1 V\alpha_2\alpha_3$, а основа дуратива — $\alpha_1 V\alpha_2 VV\alpha_3$. При этом все гласные должны быть одинаковы.

-

Глагольные формы в йоулумни

Преобразователи для глагольных форм в языке йоулумни

- Основа герундия:
- Основа дуратива:



Глагольные формы в йоулумни

Код для морфологии в йоулумне

```

### youlumne.foma ###

define Vowel [ a | i | o | u ];
define Consonant [ c | w | m | h | y | d | l | g | k | t ];
define Letter [ Consonant | Vowel ];
define Stem Consonant Vowel (Vowel) Consonant (Vowel) (Vowel) (Consonant) ;
define VerbMark "+V";
define Mood "+Ger" "+Dur";
define Mark [ VerbMark Mood ];
define VowelPattern [ [ Consonant | a ]+ | [ Consonant | i ]+ | [ Consonant | o ]+ | [
    Consonant | u ]+ ];
define Word Stem & VowelPattern;

# left context for not a leftmost vowel
define LeftContext1 Consonant Vowel [ Letter ]* ;
define VowelRemoval Vowel -> [] || LeftContext1 _ ;
define LeftContext2 Consonant Vowel Consonant ;
define DurativeVowelInsertion [..] -> [ a a | i i | o o | u u ] || LeftContext2 _ (
    Consonant) .# . ;
define GerundSuffixInsertion ["+V" "+Ger"] : [ i n a y ] ;
define DurativeSuffixInsertion ["+V" "+Dur"] : [ g a a n ] ;
define GerundStem Word .o. VowelRemoval ;
define DurativeStem GerundStem .o. DurativeVowelInsertion .o. VowelPattern ;
define Gerund [ GerundStem GerundSuffixInsertion ] ;
define Durative [ DurativeStem DurativeSuffixInsertion ] ;
define Grammar [ Gerund | Durative ] ;
push Grammar

```

Мати Пентус, Александр Пиперски, Алексей Сорокин

Математические модели в лингвистике

Описание морфологии в йоулумне

- В суффиксе дуратива происходит вставка двух одинаковых гласных.

Описание морфологии в йоулумне

- В суффиксе дуратива происходит вставка двух одинаковых гласных.
- При этом эти гласные обязаны совпадать с гласной первого слога.

Описание морфологии в йоулумне

- В суффиксе дуратива происходит вставка двух одинаковых гласных.
- При этом эти гласные обязаны совпадать с гласной первого слога.
- Для этого нужно оставлять только слова, в которых все гласные одинаковы.

Описание морфологии в йоулумне

- В суффиксе дуратива происходит вставка двух одинаковых гласных.
- При этом эти гласные обязаны совпадать с гласной первого слога.
- Для этого нужно оставлять только слова, в которых все гласные одинаковы.
- Это можно задать регулярным выражением (шаблон Vowel-Pattern).

Описание морфологии в йоулумне

- В суффиксе дуратива происходит вставка двух одинаковых гласных.
- При этом эти гласные обязаны совпадать с гласной первого слога.
- Для этого нужно оставлять только слова, в которых все гласные одинаковы.
- Это можно задать регулярным выражением (шаблон Vowel-Pattern).
- Под тот же шаблон должны подходить и возможные основы.

Преобразователь для арабского словоизменения

- Для арабского характерна “разрывная” морфология.

k t b “*писать*” (корень) + a-a + -a = kataba “(он) *писал*”

Преобразователь для арабского словоизменения

- Для арабского характерна “разрывная” морфология.

k t b “*писать*” (корень) + a-a + -a = kataba “(он) писал”

- Соответствующий преобразователь:



Преобразователь для арабского словоизменения

- Для арабского характерна “разрывная” морфология.

k t b “*писать*” (корень) + a-a + -a = kataba “(он) писал”

- Соответствующий преобразователь:



- Как описать то же самое в терминах контекстных замен?

Преобразователь для арабского словоизменения

- Для арабского характерна “разрывная” морфология.

k t b “*писать*” (корень) + a-a + -a = kataba “(он) писал”

- Соответствующий преобразователь:



- Как описать то же самое в терминах контекстных замен?
- Можно ввести маркеры для позиций после первого согласного, после второго и т.д.

Преобразователь для арабского словоизменения

- Для арабского характерна “разрывная” морфология.

k t b “писать” (корень) + a-a + -a = kataba “(он) писал”

- Соответствующий преобразователь:



- Как описать то же самое в терминах контекстных замен?
- Можно ввести маркеры для позиций после первого согласного, после второго и т.д.
- Дополнительная проблема — вставляемые гласные зависят от основы:

k t b “писать” (корень) + a-a + -a = kataba “(он) писал”

m r d “болеть” (корень) + a-i + -a = marida “(он) болел”

Преобразователь для арабского словоизменения

- Для арабского характерна “разрывная” морфология.

k t b “писать” (корень) + a-a + -a = kataba “(он) писал”

- Соответствующий преобразователь:



- Как описать то же самое в терминах контекстных замен?
- Можно ввести маркеры для позиций после первого согласного, после второго и т.д.
- Дополнительная проблема — вставляемые гласные зависят от основы:

k t b “писать” (корень) + a-a + -a = kataba “(он) писал”

m r d “болеть” (корень) + a-i + -a = marida “(он) болел”

- Кроме того, есть “обычные” префиксы/суффиксы.

Арабская морфология: описание задачи

- Очень базовый пример морфологического синтезатора.

Арабская морфология: описание задачи

- Очень базовый пример морфологического синтезатора.
- вход: корень+⟨Type⟩+⟨Voice⟩+⟨Aspect⟩+⟨Person⟩+⟨Gender⟩

Арабская морфология: описание задачи

- Очень базовый пример морфологического синтезатора.
- вход: корень+ $\langle \text{Type} \rangle + \langle \text{Voice} \rangle + \langle \text{Aspect} \rangle + \langle \text{Person} \rangle + \langle \text{Gender} \rangle$
- $\langle \text{Type} \rangle \in \{I, II\}$ — порода (базовая или интенсив)

Арабская морфология: описание задачи

- Очень базовый пример морфологического синтезатора.
- вход: корень+ $\langle \text{Type} \rangle$ + $\langle \text{Voice} \rangle$ + $\langle \text{Aspect} \rangle$ + $\langle \text{Person} \rangle$ + $\langle \text{Gender} \rangle$
- $\langle \text{Type} \rangle \in \{I, II\}$ — порода (базовая или интенсив)
- $\langle \text{Voice} \rangle \in \{\text{Act}, \text{Pass}\}$ — залог

Арабская морфология: описание задачи

- Очень базовый пример морфологического синтезатора.
- вход: корень+ $\langle \text{Type} \rangle$ + $\langle \text{Voice} \rangle$ + $\langle \text{Aspect} \rangle$ + $\langle \text{Person} \rangle$ + $\langle \text{Gender} \rangle$
- $\langle \text{Type} \rangle \in \{I, II\}$ — порода (базовая или интенсив)
- $\langle \text{Voice} \rangle \in \{\text{Act}, \text{Pass}\}$ — залог
- $\langle \text{Aspect} \rangle \in \{\text{Perf}, \text{Imperf}\}$ — вид

Арабская морфология: описание задачи

- Очень базовый пример морфологического синтезатора.
- вход: корень+ $\langle \text{Type} \rangle$ + $\langle \text{Voice} \rangle$ + $\langle \text{Aspect} \rangle$ + $\langle \text{Person} \rangle$ + $\langle \text{Gender} \rangle$
- $\langle \text{Type} \rangle \in \{I, II\}$ — порода (базовая или интенсив)
- $\langle \text{Voice} \rangle \in \{\text{Act}, \text{Pass}\}$ — залог
- $\langle \text{Aspect} \rangle \in \{\text{Perf}, \text{Imperf}\}$ — вид
- $\langle \text{Person} \rangle \in \{3\}$ — лицо
- $\langle \text{Gender} \rangle \in \{M, F\}$ — род
- Всего 16 вариантов.

Модель словообразования

Приводится по очерку арабской грамматики А. А. Зализняка.

Порода	Шаблон	Пример
I – базовая форма	К-Т-В	kataba “писать”
II – интенсив	К-ТТ-В	kattaba “много писать”

Таблица основ

Форма	Окончание перфекта	Префикс и окончание имперфекта
3m	-a	ya- -u
3f	-at	ta- -u

Таблица окончаний

Модель словообразования

Вид	Залог	Преф.	Огласовка I	Огласовка II
Перфект	Актив		а-а, i-i, а-и	а-а
Перфект	Пассив		и-и	и-и
Имперфект	Актив	уа-	Ø-и, Ø-i, Ø-а	а-и
Имперфект	Пассив	уи-	Ø-а	а-а

Таблица огласовок

Модель словообразования

Вид	Залог	Преф.	Огласовка I	Огласовка II
Перфект	Актив		а-а, i-i, а-и	а-а
Перфект	Пассив		и-и	и-и
Имперфект	Актив	уа-	∅-и, ∅-и, ∅-а	а-и
Имперфект	Пассив	уи-	∅-а	а-а

Таблица огласовок

Вариант	Огласовка перфекта	Огласовка имперфекта	пример
1	а-а	∅-а	zahara “сиять”
2	а-а	∅-и	kataba “писать”
3	а-а	∅-и	safara “отправляться в путь”
4	а-и	∅-а	marida “быть больным”
5	а-и	∅-и	hasuna “быть красивым”

Варианты огласовок

Условие задачи

- $ktb+I+Act+Perf+3+M \Leftrightarrow kataba$
- $ktb+II+Pass+Imperf+3+F \Leftrightarrow tukattabu$
- $zhr+I+Act+Imperf+3+M \Leftrightarrow yazharu$
- $sfr+I+Act+Imperf+3+F \Leftrightarrow tasfiru$
- $mrd+II+Pass+Perf+3+M \Leftrightarrow murrida$
- $hsn+I+Act+Perf+3+F \Leftrightarrow hasunat$

Алгоритм работы синтезатора

- Input — проверка корректности и вставка метки класса

Алгоритм работы синтезатора

- Input — проверка корректности и вставка метки класса
- PosInsertion — вставка маркеров позиций

Алгоритм работы синтезатора

- Input — проверка корректности и вставка метки класса
- PosInsertion — вставка маркеров позиций
- Fill — заполнение огласовок (порода, вид, залог, класс),

Алгоритм работы синтезатора

- Input — проверка корректности и вставка метки класса
- PosInsertion — вставка маркеров позиций
- Fill — заполнение огласовок (порода, вид, залог, класс),
- Prefix — вставка префиксов (вид, залог, лицо, род)

Алгоритм работы синтезатора

- Input — проверка корректности и вставка метки класса
- PosInsertion — вставка маркеров позиций
- Fill — заполнение огласовок (порода, вид, залог, класс),
- Prefix — вставка префиксов (вид, залог, лицо, род)
- Suffix — вставка суффиксов (вид, лицо, род)

Алгоритм работы синтезатора

- Input — проверка корректности и вставка метки класса
- PosInsertion — вставка маркеров позиций
- Fill — заполнение огласовок (порода, вид, залог, класс),
- Prefix — вставка префиксов (вид, залог, лицо, род)
- Suffix — вставка суффиксов (вид, лицо, род)
- Cleanup — очистка меток
- Общий преобразователь: $\text{Input} \circ \text{PosInsertion} \circ \text{Fill} \circ \text{Prefix} \circ \text{Suffix} \circ \text{Cleanup}$.

Пример работы

- $sfr+I+Act+Imperf+3+F$

Пример работы

- $sfr+l+Act+Imperf+3+F$
- Input: $C3^{sfr+l+Act+Imperf+3+F}$ (вставка метки класса)

Пример работы

- $sfr+l+Act+Imperf+3+F$
- Input: $C3^{\wedge}sfr+l+Act+Imperf+3+F$ (вставка метки класса)
- PosInsertion: $C3^{\wedge}0s1f2r3+l+Act+Imperf+3+F$ (вставка маркеров позиций)

Пример работы

- $sfr+l+Act+Imperf+3+F$
- Input: $C3^{\wedge}sfr+l+Act+Imperf+3+F$ (вставка метки класса)
- PosInsertion: $C3^{\wedge}0s1f2r3+l+Act+Imperf+3+F$ (вставка маркеров позиций)
- Fill: $C3^{\wedge}0sfir3+l+Act+Imperf+3+F$

Пример работы

- $sfr+l+Act+Imperf+3+F$
- Input: $C3^{sfr+l+Act+Imperf+3+F}$ (вставка метки класса)
- PosInsertion: $C3^{0s1f2r3+l+Act+Imperf+3+F}$ (вставка маркеров позиций)
- Fill: $C3^{0sfir3+l+Act+Imperf+3+F}$
- Prefix: $C3^{tasfir3+l+Act+Imperf+3+F}$

Пример работы

- $sfr+l+Act+Imperf+3+F$
- Input: $C3^{sfr+l+Act+Imperf+3+F}$ (вставка метки класса)
- PosInsertion: $C3^{0s1f2r3+l+Act+Imperf+3+F}$ (вставка маркеров позиций)
- Fill: $C3^{0sfir3+l+Act+Imperf+3+F}$
- Prefix: $C3^{tasfir3+l+Act+Imperf+3+F}$
- Suffix: $C3^{tasfiru+l+Act+Imperf+3+F}$

Пример работы

- $sfr+l+Act+Imperf+3+F$
- Input: $C3^{sfr+l+Act+Imperf+3+F}$ (вставка метки класса)
- PosInsertion: $C3^{0s1f2r3+l+Act+Imperf+3+F}$ (вставка маркеров позиций)
- Fill: $C3^{0sfir3+l+Act+Imperf+3+F}$
- Prefix: $C3^{tasfir3+l+Act+Imperf+3+F}$
- Suffix: $C3^{tasfiru+l+Act+Imperf+3+F}$
- Cleanup: $tasfiru$