



КАРПОВСКИЕ НАУЧНЫЕ ЧТЕНИЯ

Выпуск 8

Часть I

БЕЛОРУССКИЙ ГОСУДАРСТВЕННЫЙ УНИВЕРСИТЕТ
ФИЛОЛОГИЧЕСКИЙ ФАКУЛЬТЕТ



КАРПОВСКИЕ НАУЧНЫЕ ЧТЕНИЯ

Сборник научных статей

Основан в 2007 году

Выпуск 8

В двух частях

Часть 1

Минск
«ИВЦ Минфина»
2014

В сборнике представлены материалы Восьмых Карповских научных чтений, посвященных памяти профессора В.А. Карпова — ученого, философа, поэта, оставившего заметный след в отечественной культуре.

Адресован филологам, философам, системологам, специалистам по прикладной и компьютерной лингвистике, а также студентам, магистрантам, аспирантам, интересующимся рассматриваемыми проблемами.

Рекомендовано

Ученым советом филологического факультета
Белорусского государственного университета
(протокол № 9 от 19 июня 2014 г.)

Редакционная коллегия:

кандидат филологических наук, доцент А.И. Головня (отв. ред.);
кандидат филологических наук, доцент Н.С. Касюк (зам. ред.);
кандидат технических наук, доцент О.Е. Елисеева

Рецензенты:

кандидат филологических наук, доцент А.В. Лаврененко
кандидат педагогических наук, доцент Т.В. Игнатович

Секция 3: ОБЩАЯ ТЕОРИЯ СИСТЕМ КАК МЕТОДОЛОГИЯ НАУКИ

Барбук С.Г. (Минск, БГЭУ) Языковые универсалии.....	221
Ван Цзин (Минск, БГУ) Возможность изучения коннотации в корпусном исследовании.....	225
Ван Цин (Минск, БГУ) Особенности имени существительного в грамматике русского и китайского языков.....	228
Гецэвіч Ю.С., Окрут Т.І., Міхайлова Я.А. (Мінск, НАН РБ, БДУ) Распрацоўка лінгвістычных рэсурсаў для алгарытмаў ідэнтыфікацыі рэшлік дыялогаў у электронных тэкстах мастацкай тэматыкі на беларускай і рускай мовах.....	231
Гецэвіч Ю.С., Скопінава А.М. (Мінск, АПП НАН Беларусі) Лінгвістычныя рэсурсы для пераўтварэння колькасных выразаў з адзінкамі вымярэння тыпу «лічба-сімвал» у словазлучэнні для беларускай і рускай мовы.....	236
Гецэвіч Ю.С. (Мінск, АПП НАН Беларусі), Барадзіна Ю.С. (Мінск, БДУ) Класіфікацыя фразаў дыялогаў па эматыўных прыкметах на матэрыяле рускіх і беларускіх мастацкіх твораў.....	240
Гецэвіч Ю.С., Лысы С.І. (Мінск, АПП НАН Беларусі) Рашэнне прыкладных лінгвістычных задач пры дапамозе сэрвісаў рэсурсу www.corpus.by	243
Глинка Е.В. (Мінск, МГЛУ) Проявление симметрии и асимметрии в условиях русско-белорусского двуязычия	247
Головня А.И. (Мінск, БГУ) Системная симметрично-асимметричная номинация в абревиации.....	251
Иващенко В.П. (Мінск, БГУИР) Пространственно-временные интервальные бинарные отношения на множествах событий и их языковые средства представления.....	255

Секция 4: ПРИКЛАДНАЯ ЛИНГВИСТИКА В БЕЛАРУСИ: СОСТОЯНИЕ И ПЕРСПЕКТИВЫ РАЗВИТИЯ

Аскерко Д.С. (Мінск, МГЛУ) Специфика базы данных системы автоматического определения средств выражения вербальной агрессии в текстах англоязычных СМИ.....	259
Бочкова А.Л. (Мінск, МГЛУ) Лингвистическая база данных как основа системы автоматического извлечения мнений участников интернет-коммуникаций.....	263
Гусева Н.Ю. (Мінск, БГУ) Трудности в преподавании курса «Основы информационных технологий» иностранным студентам.....	266

Таким образом, морфологические признаки имени существительных китайского и русского языков сильно отличаются. В китайском языке не все существительные имеют категории рода, кроме собственных имен людей, но по их именам не определяется пол человека. Категория числа в русском языке проявляется в окончаниях слов. Изменение окончаний русских слов по падежам называется склонением. В китайском языке число существительного выражается суффиксом «儿», а падежи отсутствуют, вместо них существуют строгие правила по порядку слов.

ЛІТЕРАТУРА

1. Ахманова, О.С. Словарь лингвистических терминов. – М.: Сов. энциклопедия, 1966.
2. Белошапкова, В.А. Современный русский язык: учеб. для филол. спец. ун-тов // В.А. Белошапкова, Е.А. Брызгунова, Е.А. Земская и др.; Под ред. В.А. Белошапковой [Электронный ресурс]. – Режим доступа: <http://sci-book.com/yazyik-russkiy/sovremennoiy-russkiy-yazyik-ucheb-dlya-filol.html>. – Дата доступа: 26.02.2014.
3. Корпус современного китайского языка [Электронный ресурс]. – Режим доступа: http://ccl.pku.edu.cn:8080/ccl_corpus/index.jsp?dir=xiandai – Дата доступа: 26.02.2014.
4. 刘守军 词类 (Категория слов) / 刘守军 [Электронный ресурс]. – Режим доступа: http://study.hhit.edu.cn/subject/CourseWare_Detail.aspx?TeachCourseWareID=1684. – Дата доступа: 04.03.2014.
5. 孙浩成 现代汉语语法大全 (Грамматика современного китайского языка) / 孙浩成 [Электронный ресурс]. – Режим доступа: <http://wenku.baidu.com/view/0ea2c833-43323968011c9253.html>. – Дата доступа: 04.03.2014.
6. 朱雪峰, 王惠 现代汉语量词与名词的子类划分 (Подкатегории счётных слов и существительных современного китайского языка) / 朱雪峰, 王惠 [Электронный ресурс]. – Режим доступа: <http://www.tigernt.com/yyy23.php>. – Дата доступа: 04.03.2014.

Ю.С.Гецэвіч, Т.І.Окрут, Я.А.Міхайлова (Мінск, НАН РБ, БДУ)

РАСПРАЦОЎКА ЛІНГВІСТЫЧНЫХ РЭСУРСАЎ ДЛЯ АЛГАРЫТМАЎ ІДЭНТЫФІКАЦЫІ РЭПЛІК ДЫЯЛОГАЎ У ЭЛЕКТРОННЫХ ТЭКСТАХ МАСТАЦКАЙ ТЭМАТИКІ НА БЕЛАРУСКАЙ І РУСКАЙ МОВАХ

На сёняшні дзень стварэнне аўдыёкніг можа праходзіць двумя шляхамі: праз запис надыктоўкі тэксту чалавекам і праз аўтаматычнае стварэнне аўдыёфайлаў на аснове сінтэзу маўлення па тэксце. Абодва варыянты забяспечваюць у большасці сваёй аднаголосае агучванне, пры гэтым першы выпадак патрабуе піmat выдаткаў часу. Але, калі зварнуць увагу на звычайны мастацкі тэкст, то ён налічвае вялікую колькасць дыялогаў паміж рознымі персанажамі, у сувязі з чым з'яўляецца матываванне жаданне стваральніка аўдыёкніг выкарыстаць розных дыктараў ці сінтезаваных галасы, каб аўдыёкніга была больш набліжанай да адлюстравання ўнікальных характеристык маўлення персанажаў.

У напрамку стварэння шматгалосага сінтэзу маўлення па тэксце (CCMT) аўтары пачалі працу яшчэ летам 2013 года. У якасці асяроддзя

распрацоўкі алгарытмаў выкарыстоўвалася праграма NooJ [1]. NooJ — гэта міжнародная лінгвістычная праграма, якая дазваляе распрацоўваць сінтаксічныя і марфалагічныя граматыкі і тэставаць іх на вялікай колькасці тэкстаў. З іх дапамогай можна потым ствараць сінтаксічныя анататы і экспартаваць размечаны тэкст як файл XML для далейшай апрацоўкі. На дадзены момант здзяйсняеца аўтаматычнае шматгалосае агучванне дыялогаў з рэплікамі, дзе прысутнічаюць аўтарскія каментары, пры гэтым распрацаваныя алгарытмы былі адаптаваны і для рускай мовы. Непасрэдна мае месца ідэнтыфікацыя роду персанажа па такіх паказчыках ва ўстаўках слоў аўтара, як дзеясловы мінулага часу адзіночнага ліку з прыкметамі роду (*сказаў*, *сказала*), уласныя імёны (*Алесь*, *Майка*), і назоўнікі, якія пазначаюць размоўцу (*бачка*, *дзяўчынка*).

Напачатку вялася ручная праца: быў сабраны корпус тэкстаў, у якім асобна былі пазначаны ўсе рэплікі са ўстаўкамі слоў аўтара. Для іх адначасова пазначаўся род персанажа — мужчынскі, або жаночы, вызначаліся паказчыкі роду.

На гэтым этапе таксама былі выведзеныя ніжэй прыведзеныя структуры афармлення простай мовы дыялогаў з наступнымі абазначэннямі: П — слова персанажа; А — слова аўтара; дужкі (,) — пачатак і завяршэнне набору варыяцый знакаў прыпынку; | — сімвал або (раздзяленне знакаў прыпынку ў наборы варыяцый знакаў прыпынку).

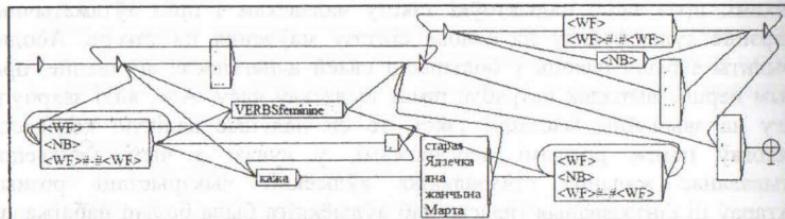
1. Словы моўцы без слоў аўтара:

 - П (! | !! | !!! | ? | ?? | ... | .).
 - 2. Словы моўцы са словамі аўтара ў канцы:

 - П (, | ! | !! | !!! | ? | ?? | ... | .) — А (... | .).
 - 3. Словы моўцы з некалькімі аўтарскімі ўстаўкамі:

 - П (, | ! | !! | !!! | ? | ?? | ... | .) — А (, | ... | . | : | .) — П (, | ! | !! | !!! | ? | ?? | ... | .)
 - (— А (, | ... | . | : | .) — П (, | ! | !! | !!! | ? | ?? | ... | .)).

На аснове атрыманых дадзеных былі распрацаваныя алгарытмы DirectSpeechMasculine і DirectSpeechFeminine для попушку рэплік са ўстаўкамі слоў аўтара, якія належаць персанажам мужчынскага ці жаночага роду. На малюнку 1 прадстаўлены падкампанент алгарытму ідэнтыфікацыі рэплік персанажаў жаночага роду.



Мал. 1 Сінтаксічны падкампанент для вызначэння рэплік персанажаў жаночага роду

Ідентыфікацыя роду персанажа ў дадзеных алгарытмах здзяйсняецца за кошт слоў-паказчыкаў роду, а непасрэдна праз падграфы VERBSmasculine і VERBSfeminine, якія ўключаюць спіс дзеясловаў мінулага часу адзіночнага ліку з наяўнымі атрыбутамі роду.

Па меры папаўнення спісу дзеясловаў-паказчыкаў роду былі створаныя асобныя лінгвістычныя рэсурсы ў выглядзе слоўнікаў для беларускай і рускай моў (мал. 2). У іх парамі прадстаўленыя дзеясловы мінулага часу ў формах для жаночага і мужчынскага роду. Такім чынам, замест падграфа VERBSmasculine ціпер прымяняюцца спецыяльныя тэгі (категорыі) SpeechAct (семантычная пазнака для дзеясловаў-каментароў простай мовы) і Masculine (мал. 3), адпаведна для падграфа VERBSfemenine — тэгі SpeechAct і Feminine. Акрамя таго, у алгарытме прадугледжана ідентыфікацыя роду персанажаў па спісу назоўнікаў, на аснове якіх на далейшым этапе таксама будуть створаныя слоўнікі.

Dictionary contains 429 entries

Dictionary contains 293 entries

сцвердзіла, VERB+SpeechAct+Feminine
смылаў, VERB+SpeechAct+Masculine
смыла, VERB+SpeechAct+Feminine
трываў, VERB+SpeechAct+Masculine
трывала, VERB+SpeechAct+Feminine
ударыў, VERB+SpeechAct+Masculine+FLX=ЎVERB1
ударыла, VERB+SpeechAct+Feminine+FLX=ЎVERB1
удзмокнуў, VERB+SpeechAct+Masculine+FLX=ЎVERB1
удзмокнула, VERB+SpeechAct+Feminine+FLX=ЎVERB1

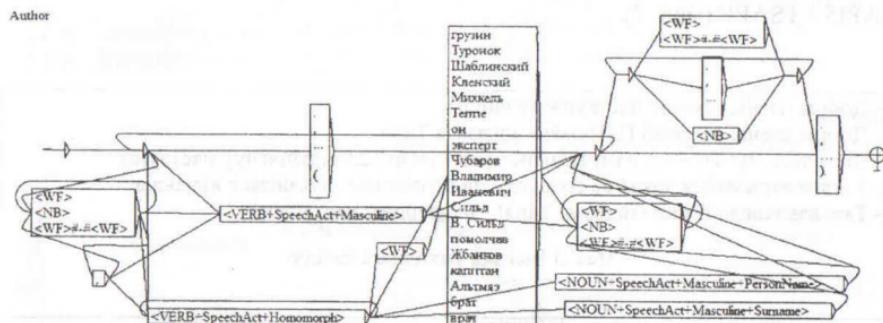
(a)

брала, VERB+SpeechAct+Feminine
взмохнул, VERB+SpeechAct+Masculine
взмохнула, VERB+SpeechAct+Feminine
вздыхал, VERB+SpeechAct+Masculine
вздыхала, VERB+SpeechAct+Feminine
взмоліўся, VERB+SpeechAct+Masculine
взмолілася, VERB+SpeechAct+Feminine
взмокнул, VERB+SpeechAct+Masculine
вмешалася, VERB+SpeechAct+Feminine

(b)

Мал. 2. Слоўнікі дзеясловаў-паказчыкаў роду для беларускай (а) і рускай (б) моў

Author

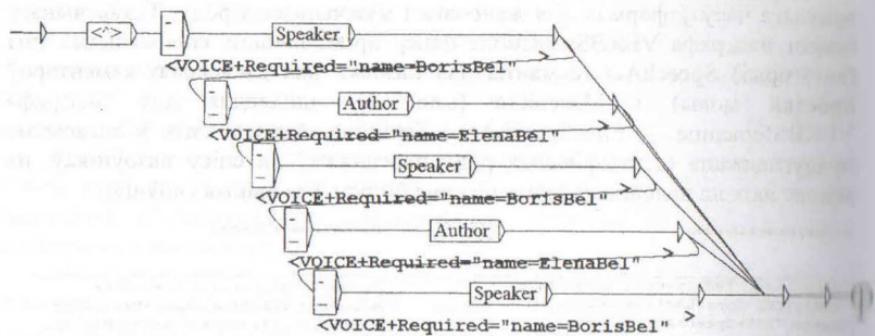


Мал. 3 Падграф Author у алгарытме для ідентыфікацыі рэсплік персанажаў мужчынскага роду

Для таго каб працу гэтых граматык можна было выкарыстоўваць у CCMT пад стандарт SAPI 5.1, то неабходна прывесці тэксты да выгляду SAPI TTS XML [2]:

```
<VOICE Required="name=[Назва голасу ў сістэме]">
...Тэкст для агучвання...
</VOICE>
```

Для гэтага ў распрацаваныя алгарытмы былі дададзены маркеры абазначэння пляхоў, якія спрацавалі ў алгарытмах (Мал. 4). Маркеры настроены так, што непазначаны тэкст твору і словы аўтара чытаюцца голасам ElenaBel (Elena для рускай мовы), мужчынскія рэшлікі голасам — BorisBel (Boris для рускай мовы), а жаночыя — AlesiaBel (Alesia для рускай мовы).



Мал. 4 Дададзеная функцыя анатавання праз VOICE-тэгі

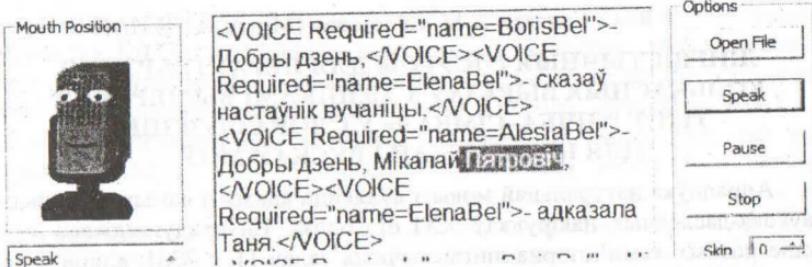
Так, напрыклад, тэкст на мал. 5 пасля апрацоўкі будзе выглядаль як на мал. 6. Пасля такой апрацоўкі тэкст можна выкарыстоўваць у праграме SAPI5 TTSAPP (мал. 7).

- Добры дзень, - сказаў настаўнік вучаніцы.
- Добры дзень, Мікалай Пятровіч, - адказала Таня.
- Ці рашылі Вы задачку па трыганаметрыі нумар 123,- працягнуў настаўнік.
- У мяне атрымаўся адказ 60 градусаў, ці правільна? - шкавілася вучаніца.
- Так, дакладна! Ты малайчына, Таня! - пацвердзіў настаўнік.

Мал. 5 Выгляд зыходнага тэксту

```
<VOICE Required="name=BorisBel">- Добры дзень,</VOICE><VOICE Required="name=ElenaBel">- сказаў настаўнік вучаніцы.</VOICE>
<VOICE Required="name=AlesiaBel">- Добры дзень, Мікалай Пятровіч,</VOICE> <VOICE Required="name=ElenaBel">- адказала Таня.</VOICE>
<VOICE Required="name=BorisBel">- Ці рашылі Вы задачку па трыганаметрыі нумар 123,</VOICE> <VOICE Required="name=ElenaBel">- працягнуў настаўнік </VOICE>
```

Мал. 6 Анатаваны праз VOICE-тэгі тэкст



Мал. 7 Аўтаматычнае пераключэнне галасоў у праграме SAPI5 TTSAPP

На выніках тэсціроўкі створаных алгарытмаў на тэставым корпусе шматгалосае агучванне рэплік персанажаў са ўстаўкамі слоў аўтара ў электронных тэкстах здзяйсняеца з дакладнасцю больш за 75 %. Дэталёвая ацэнка распрацаваных алгарытмаў адлюстроўваеца ў табліцах 1 і 2, дзе N — вызначаныя экспертым правільныя рэплікі ў тэксце, M — правільна знайдзеныя алгарытмам рэплікі, L — усе знайдзеныя алгарытмам рэплікі.

Таблица 1

Ацэнка працы сінтаксічных алгарытмаў NooJ для беларускага корпусу тэксту

Назвы граматык	Дакладнасць (P)	Паўната (R)	Сярэдняя гарманічная величыня (F1-measure), %
	(M/L)	(M/N)	$2*P*R*100 / (P+R)$
DirectSpeechMasculine	$143/145 = 0,986$	$143/165 = 0,866$	92,2
DirectSpeechFeminine	$57/58 = 0,982$	$57/68 = 0,838$	90,4

Таблица 2

Ацэнка працы сінтаксічных алгарытмаў NooJ для рускага корпусу тэксту

Назвы граматык	Дакладнасць (P)	Паўната (R)	Сярэдняя гарманічная величыня (F1-measure), %
	(M/L)	(M/N)	$2*P*R*100 / (P+R)$
DirectSpeechMasculine	$300/339 = 0,885$	$300/456 = 0,657$	76,4
DirectSpeechFeminine	$70/90 = 0,777$	$70/92 = 0,761$	76,9

У далейшым плануецца павышаць дакладнасць працы распрацаваных алгарытмаў, а таксама распрацаваць кампанент ідэнтыфікацыі роду персанажаў па словах персанажаў.

ЛІТАРАТУРА

- Лінгвістычны працэсар NooJ [Электронны рэсурс]. – 2002. – Рэжым доступу: <http://www.nooj4nlp.net/pages/nooj.html>. – Дата доступу: 01.07.2013.
- XML TTS Tutorial (SAPI 5.3) // Microsoft Developer Network [Electronic resource]. – 2013. – Mode of access: <http://msdn.microsoft.com/en-us/library/ms717077%28v=vs.85%29.aspx>. – Date of access: 29.07.2013.