



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. Елиссеева

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 беларус- кай і рускай мовах.....	231
Гецэвіч Ю.С., Скопінава А.М. (Мінск, АПП НАН Беларусі) Лінгвіс- тычныя 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. (Минск, МГЛУ) Проявление симметрии и асимметрии в условиях русско-белорусского двуязычия	247
Головня А.И. (Минск, БГУ) Системная симметрично-асимметричная номинация в абревиации.....	251
Иващенко В.П. (Минск, БГУИР) Пространственно-временные интер- вальные бинарные отношения на множествах событий и их языковые средства представления.....	255

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

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

Ю.С. Гецэвіч, А.М. Скопінава (Мінск, АПІ НАН Беларусі)

**ЛІНГВІСТЫЧНЫЯ РЭСУРСЫ ДЛЯ ПЕРАЎТВАРЭННЯ
КОЛЬКАСНЫХ ВЫРАЗАЎ З АДЗІНКАМІ ВЫМЯРЭННЯ
ТЫПУ «ЛІЧБА-СІМВАЛЬ» У СЛОВАЗЛУЧЭННІ
ДЛЯ БЕЛАРУСКАЙ І РУСКАЙ МОЎ**

Апрацоўка натуральнай мовы з'яўляецца адным з самых актуальных навукова-даследчых накірункаў XXI стагоддзя. Ён прадугледжвае вырашэнне розных камп'ютэрна-лінгвістычных задач [1, с. 333], адной з якіх можна назваць апрацоўку складана ці спецыфічна структураванай інфармацыі ў электронных тэкстах: табліц, формул, схем, спасылак, зносак і г.д. У дадзеным дакладзе аўтары канцэнтруюцца на колькасных выражах з адзінкамі вымярэння (КВАВ) — спалучэннях колькасных паказчыкаў (перададзеных на пісьме пасродкам лічбаў) і пазначэнняў мерных адзінак (літарных сімвалаў), напрыклад: $1,72 \text{ г}/\text{см}^3$, 19640 км , 55° , $6,387 \text{ сутак}$, $1212 \pm 16 \text{ км}$, $1,9 \times 10^{21} \text{ кг}$ і г.д. Будову КВАВ можна ўяўіць фармальна, што адлюстравана ў табліцы 1. У ёй пад X маецца на ўвазе колькасны паказчык (лік), а пад Y — сімвалы літар; знак вертыкальнай рысы размяжкоўвае прыклады.

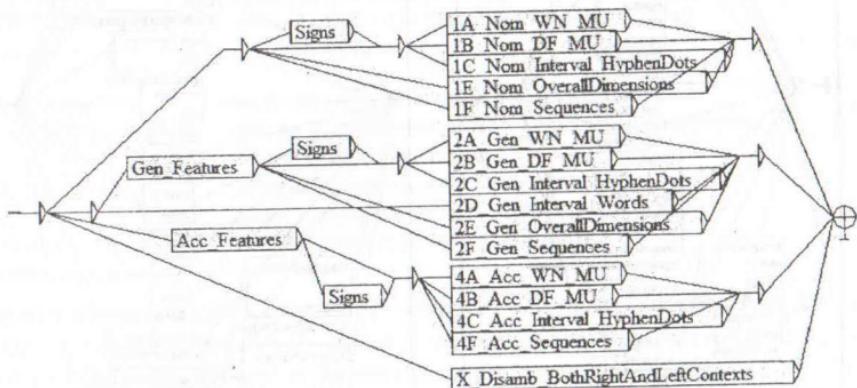
Табліца 1

Мадэлі фармальнаага ўяўлення КВАВ

№	Мадэль	Прыклад
1.	$X Y$	$12\% 40-50 \text{ тыс. м}$
2.	$X Y/Y$	$0,5144444 \text{ м}/\text{с}$
3.	$X-[...]\times Y$	$1-1,5 \text{ года} +13\dots+19^\circ\text{C}$
4.	$X-[...]\times Y/Y$	$0,1-5,7 \cdot 10^{-2} \text{ м}/\text{с}$
5.	$\sim[+\pm><]X Y$	$\pm 0,3^\circ > 6 \text{ зв}$
6.	$\sim[+\pm\leftrightarrow]X Y/Y$	$\sim 107 \text{ К}/\text{с} \sim 9,8 \text{ м}/\text{с}^2$
7.	$X,[i] X Y$	$2 \text{ і } 4 \text{ метры}$
8.	$X, X, X Y$	$5, 6, 7 \text{ шт.}$
9.	$X Y - X Y$	$0,1 \text{ Гц} - 300 \text{ кГц}$
10.	$X \times X Y$	$1136 \times 640 \text{ пікселяў}$
11.	$X \times X \times XY$	$146,8 \times 75,3 \times 8,9 \text{ мм}$
...

Неабходнасць правільнай апрацоўкі падобных лічба-сімвальных канструкцый актуальная і для навуковай, і для бытавой сферы жыцця, напрыклад, для дадзеных ад штучных спадарожнікаў і касмічных зондаў; медыцынскіх аналізаў (тэмпература, крываны ціск, пульс, цукар, халестэрин, гемаглабін...); навуковых даследаванняў; кулінарных рэцептаў; прагнозаў надвор'я; этикетак на спажывецкіх таварах; апісанняў тавараў у онлайн-крамах; каментарыяў да спартыўных мерапрыемстваў; турыстычных і іншых даведнікаў і г.д.

У працах [2; 3] аўтарамі былі прапанаваныя алгарытмы-рапшэнні апрацоўкі KBAB у выглядзе канчатковых аўтаматаў, якія дазваляюць эмуляваць працу марфалагічных і сінтаксічных граматык. Для іх стварэння быў выкарыстаны наладжвальны лінгвістычны працэсар NooJ. На малюнку 1 прадстаўлена апошняя мадыфікацыя алгарытму, які зараз апрацоўвае KBAB для беларускай і рускай моў ужо ў трах склонах: назоўным, родным і вінавальным (раней гаворка вялася толькі пра назоўны). Акрамя гэтага, будова дадзенага алгарытму заснованая ўжо на мадэлях будовы саміх KBAB, напрыклад, галіна з графам *1E_Nom_OverallDimensions* спрацуе для мадэляў KBAB пад нумарамі 10 і 11 у табліцы 1.

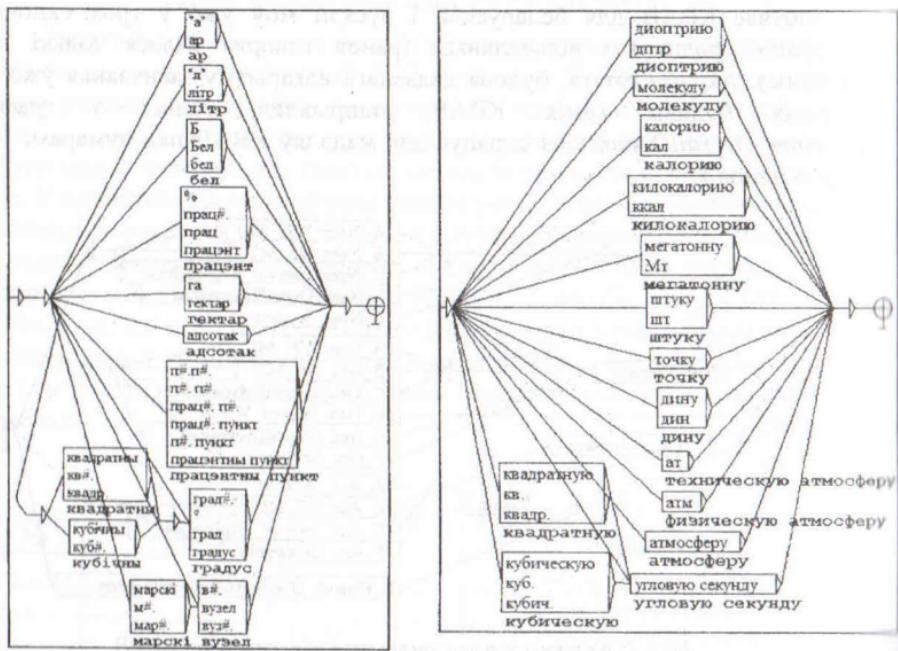


Мал. 1. Агульны выгляд алгарытму для апрацоўкі KBAB

Апрацоўка KBAB прадугледжвае іх папярэднюю ідэнтыфікацыю і аналіз. Пад ідэнтыфікацыяй будзем разумець непасрэдны пошук у электронных тэкстах колькасных паказчыкаў (лічбаў), пазначэння адзінак (сімвалаў), а таксама спецыфічнага акружэння, якое можа ўпłyваць на граматычныя катэгорыі ідэнтыфікаванага KBAB, напрыклад: *5 м — 5 метраў* (назоўны/вінавальны склон), *каля 5 м — каля пяці метраў* (родны склон), *роўны 5 м — роўны пяці метрам* (давальны склон) і г.д. Вызначэнне такога ўпływu на KBAB з боку акружэння і з'яўляенца аналізам. Таксама важна прааналізаваць і элементы KBAB: прыналежнасць паказчыка колькасці да цэлых ці дзесятковых лікаў, са знакамі ці без знакаў; прыналежнасць ідэнтыфікаванай адзінкі вымярэння да Сістэмы Інтэрнацыональнай (SI), распрацаванай Міжнародным бюро мер і вагаў [4]. Нарэшце апрацоўка KBAB заключаецца ў іх пераўтварэнні ў слова і канчатковым «склейванні» ўсіх элементаў у граматычна правільная словазлучэнні.

Трэба адзначыць, што нягледзячы на машыннае паходжанне алгарытмаў, іх карэктная праца немагчыма без адпаведных лінгвістычных

рэурсаў, пад якім мы маём на ўвазе наборы разгортак колькасных паказыкаў (лічбаў) і пазначэння адзінак вымярэння (літарных сімвалаў) у цэлыя слова. Іх распрацоўка і была задачай дадзенага даклада (малюнак 2).



(a)

(b)

Мал. 2. Лінгвістычны рэурс у выглядзе графа для апрацоўкі пазначэння ў дадатковых адзінках вымярэння для беларускай (а) і рускай (б) моў

Падкрэслім, што лінгвістычныя рэсурсы непасрэдна ўбудаваныя ў алгарытм у выглядзе асобных графаў, а не падключаныя, напрыклад, у якасці самастойных слоўнікаў. На дадзены момант апрацоўваецца 120 адзінак вымярэння ў розных відах запісу. Дзеля зручнасці стварэння і паўната рэсурсаў патрэбна было перш за ўсё скласці ліст з адзінкамі вымярэння і размежаваць адзінкі ў некалькі групп. За аснову была выкарыстаная класіфікацыя Міжнароднага бюро мер і вагаў: базавыя адзінкі СІ, вытворныя ад адзінак СІ і пазасістэмныя адзінкі. Пазней, па меры таго як алгарытм увесці час тэставаўся на беларускай і рускамоўных тэкстах масівах навукова-тэхнічнай тэматыкі, спіс адзінак значна папоўніўся. Так, усе астатнія адзінкі, не апісаныя СІ, а таксама слова, якія ўмоўна можна лічыць адзінкамі вымярэння (напрыклад, шт. ад штука), увайшли ў алгарытм асобным дадатковым класам Extra. На малюнку 2 як раз прадстаўлены выгляд гэтага графу менавіта для беларускай і рускай моў. Вынікі выкарыстання алгарытма дэманструюцца ў табліцы 2.

Фрагменты вынікаў апрацоўкі алгарытмам беларуска- (а) і рускамоўнай (б)
навукова-тэхнічнай тэкставай інфармацыі

Выгляд у тэксле	Пасля апрацоўкі алгарытмам
	(а)
займае 36,4 % 1136x640 пікселяў на 1,3 мегапікселя на 1,5-7 адсоткаў 1430 мАг 500-600 кв. метраў	займае трыццаць шэсць цэлых чатыры дзесяткі працэнта адна тысяча сто трыццаць шэсць сот сорак пікселяў на адну цэлую трох дзесяткі мегапікселя на адну цэлую пяць дзесяткі дэфіс сем адсоткаў адна тысяча чатырыста трыццаць міліампер-гадзін пяцьсот дэфіс шэсцьсот квадратных метраў
	(б)
0,01 МДж ~ 0,1 МДж более 40 га 20-210 мм +25° С свыше 2000 м	ноль целых одна сотая мегаджуля около нуля целых одной десятой мегаджуля более сорока гектаров двадцать дефис двести десять миллиметров плюс двадцать пять градусов Цельсия свыше двух тысяч метров

У заключэнні падкрэслім: значнасць лінгвістычных рэсурсаў для камп'ютэрных рашэнняў задач, звязаных з апрацоўкай тэкставай інфармацыі, немагчыма пераацаніць. Чым лепш распрацаваныя рэсурсы, тым вышэйшае значэнне паўнатаў ўсяго алгарыту — найбольш важнага паказчыка якасці алгарыту, акрамя дакладнасці. Паўната вылічваецца як вынік дзялення колькасці КВАВ, якія алгарытм правільна апрацаўваў, на реальную колькасць КВАВ ва ўсім тэкставым множстве, якую падлічыў экспер特. Зараз паўната алгарыту дасягае 75 %. У бліжэйшых планах аўтараў палепшыць гэтае значэнне праз тэстуванне алгарыту і наступную дапрацоўку яго лінгвістычных рэсурсаў на дадатковым тэкставым множстве. У дойгатэрміновай перспектыве мае быць укараненне алгарыту ў сістэму сінтэзу маўлення па тэксле дзеля большай сэнсавай дакладнасці і правільнасці, а таксама для правільнай інтанацийнай і прасадычнай афарбоўкі тэкстаў для агучвання.

ЛІТАРАТУРА

- Гецэвіч, Ю.С. Метод пабудовы кампанентаў сінтэзу маўлення па тэксле для натуральна-маўленчага інтэрфейса пры дапамозе NooJ / Ю.С. Гецэвіч, А.М. Скопінава, Т.І. Округт // Открытые семантические технологии проектирования интеллектуальных систем = Open Semantic Technologies for Intelligent Systems (OSTIS-2014): материалы IV Междунар. науч.-техн. конф. (Мінск, 20–22 февраля 2014 года) / редкол.: В.В. Голенков (отв. ред.) [и др.]. – Мінск: БГУІР, 2014 г. – С. 333–338.
- Hetsevich, Yu.S. Transforming quantitative expressions with measurement units into orthographic words for text-to-speech synthesis to Belarusian and Russian / Yu.S. Hetsevich, A.M. Skopinava // Вестник МГЛУ. Сер. 1, Филология. – 2013. – № 3. – С. 133–144.
- Гецэвіч, Ю.С. Мадэльванне і распрацоўка сістэм пошуку колькасных выразаў з адзінкамі вымярэння ў электронных тэкстах на беларускай і рускай мовах / Ю.С. Гецэвіч,

А.М. Скопінава, А.Ф. Есіс // Развитие информатизации и государственной системы научно-технической информации (РИНТИ-2013): доклады XII Международной конференции (Минск, 20 ноября 2013 г.). – Минск: ОИПИ НАН Беларусь, 2013. – С. 282–287.

4. Апісанне СІ на сایце Міжнароднага бюро мер і вагаў [Электронны рэсурс]. – 2006. – Рэжым доступу: http://www.bipm.org/en/si/si_brochure/general.html. – Дата доступу: 15.04.2014.

Ю.С. Гецэвіч (Мінск, АПП НАН Беларусі), Ю.С. Барадзіна (Мінск, БДУ)

**КЛАСIFIКАЦЫЯ ФРАЗАЎ ДЫЯЛОГАЎ ПА ЭМАТЫЎНЫХ
ПРЫКМЕТАХ НА МАТЭРЫЯЛЕ РУСКИХ И БЕЛАРУСКИХ
МАСТАЦКИХ ТВОРАЎ**

Сінтэз маўлення знаходзіць прымянењне ў розных сферах, напрыклад, пры стварэнні аўтаадказчыкаў, натуральна-моўных інтэрфейсаў, агучванні інфармацыйных паведамленняў у транспарце, на вакзале, у аэрапорце і г.д. Акрамя таго, тэхналогіі сінтэзу маўлення могуць выкарыстацца для машыннага стварэння аўдыёкніга. Звычайна гэта вымагае сур'езнай працы дыктараў і актораў, але з дапамогай існуючых напрацовак у сферы сінтэзу маўлення працэс можа быць аўтаматызаваны.

У лабараторыі распознавання і сінтэза маўлення Аб'яднанага інстытуту праblem інфарматыкі НАН Беларусі быў распрацаўваны сінтэзатор, які тэхнічна ўжо можа «чытаць кнігі» [1, 269]. Тым не менш, працэс якаснага сінтэзу маўлення яшчэ не скончаны, і застаецца некалькі істотных праблемаў, якія дагэтуль не былі вырашаны, і адна з іх — гэта праблема інтанациі.

У п'есах аўтары спрашчаюць працу актораў з дапамогай рэмарак, якія падказваюць неабходную інтанацию. У дыялогах празаічных тэкстаў прысутнічаюць словаў аўтара, здольныя выконваць гэту ж функцыю. Так, прыведзены ніжэй тэкст, калі будзе агучаны акторам у аўдыёкнізе, ніколі не будзе прачытаны манатонна: эмоцыі моўцы бачны праз знакі прыпынку, сутнасць самой фразы, і, не ў апошнюю чаргу, праз «падказкі» ў словам аўтара.

— Ад нараджэння вольныя! — люта роў ён. — Вось вам вашы вольнасці! Усіх іх выразаць!

Так, для якаснага стварэння аўдыёкніга з дапамогай сінтэзатора маўлення трэба ўлічваць эмоцыі, закладзеныя ў рэпліках герояў і словам аўтара.

Такім чынам, наступны артыкул знаёміць з першаснымі вынікамі працы, мэта якой была ў тым, каб знайсці ў фразах дыялогаў ідэнтыфікатары эматыўнай палярнасці (позітыўны, негатыўны, нейтральны) і пранаваць магчымыя сродкі іх фармалізацыі, а таксама пратэсціраваць іх на невялікім працоўным корпусе.

Даследванне вядзеца адначасова для беларускай і рускай моў. Для беларускай мовы ў якасці матэрыяла быў выбраны твор Алеся Рукаля «На