

Sonja Wölkowa
(Serbski institut, Budyšin)

Tekstowy korpus a dalše informaciske srědk wo hornjoserbskej rěči w interneće

W dobie globalizacji a přiběraceje omniprezency interneta steji wopisanje hornjoserbštiny před nowymi wužadanjemi – Franc Šen je situaciju 2012 na konferency w Gdańsku jara markantnje charakterizoval: „štož njeje w interneće, njeeksistuje” (Šen, 2013, s. 131). A tak nastawa a rosće potrjeba za digitalnje a přez internet přistupnymi informaciskimi žórlami wo hornjoserbštinje kaž za praksu tak tež za wědomostne sledženie. Na aktualnosć tuteje problematiki pokazuje w lěće 2013 w nadawku Załožby za serbski lud założena dželowa skupina „Serbščina w nowych medijach”. Wona je jako tuchwilu najwažniši nadawk identifikowała a wobzamknyła wudželanie noweho němsko-hornjoserbskeho słownika w interneće, a tutomu nadawkej mamy so jako rěčespytnicy stajić. Jako palaca začuwa so tuta potrjeba wosebje tež hladajo na to, zo je so za delnjoserbštinu w poslednim lětdzesatku w delnjoserbskim wotriedze Serbskeho instituta zrealizował a w syći spřistupnił cyły system informaciskich srédkow, ke kotremuž słuša nimo němsko-delnjoserbskeho słownika tež digitalny přistup k najwažnišim delnjoserbsko-němskim słownikam Zwahra, Muki, Śwjele a Starosty kaž tež delnjoserbski tekstowy korpus (Dolnoserbski tekstowy korpus, n.d.; www.dolnoserbski.de).

W swojim přednošku chcu tu předstajić hornjoserbski tekstowy korpus HoTKo w konteksće dalších digitalnych projektow za hornjoserbštinu,

This is an Open Access article distributed under the terms of the Creative Commons Attribution 3.0 PL License (creativecommons.org/licenses/by/3.0/pl/), which permits redistribution, commercial and non-commercial, provided that the article is properly cited. © The Author(s) 2014.

Publisher: Institute of Slavic Studies, PAS & The Slavic Foundation
[Wydawca: Instytut Sławistyki PAN & Fundacja Sławistyczna]

realizowanych, přihotowanych a planowanych w Serbskim instituće. Wobšerniši přehlad wo prezency serbskich wobsahow w interneće powšitkownje je podał w hižo mjenowanym přednošku w Gdańsku Franc Šen, při tym wšak njebě městna na nadrobnishe přestajenje jednotliwych poskitkow (Šen, 2013). Prěnje plany stworjenja tajkich internetowych pomocnych srédkow za hornjoserbštinu sahaja do prěnjeje połožcy 90tych lét 20. lětstotka. Tehdy načisny so w Serbskim instituće projekt jednorěčneho hornjoserbskeho słownika, kotryž měješe primarnje w digitalnej formjeastać (Šołćina & Wornar, 1996). Bohužel njeje so tutón projekt personalnych přičin dla realizować móhł. Tola w přihotowanskej fazy w zwisku z tutymi słownikarskimi planami započa so w lěće 1996 dželo na digitalnym hornjoserbskim tekstowym korpusu, kotryž eksistuje hač do džensnišeho a so dale wuwiwa (přir. Wölkowa, 2013). Jeho zakłady (runje tak kaž mjenowany słownikarski projekt) je koncipowały a stwořil Edward Wornar, tehdy sobudžělačer Serbskeho instituta, nětko profesor Instituta za sorabistiku na Lipšcanskej uniwersiće. Po jeho wotchadźe na profesuru w Lipsku w lěće 2003 je zamołwitość za korpus přešla na awtorku předležaceho přinoška w kooperacji z nawodu Serbskeje centralneje biblioteki Francom Šenom.

Upper Sorbian Text Corpus -- Hornjoserbski tekstowy korpus

Tutón interface služi k vuhödzenju tekstového korpusa přez ZZZ. Možeće zapodać, kotre teksty mają so přepýtać, hač ma so za jednorymi słowani abo za prawidłownymi wurazami pytać, kelko linkow konteksta so podawa, abo hač ma so statistika formow napisać.

This interface is for exploiting the text corpus via WWW. You can specify which texts you want to search, whether to search for strings or regexps, how many lines of context you want or whether you want statistics of forms.

Questions/Prašenja? sonja@serbski-institut.de

Wo kodérowanju hlej [na tutej stronje](#).

Information on the encoding of the texts you'll find [here](#).

Pytanje/Search

Pýtaj/Search:

Typ pytanego wuraza/Type of expression:

jednory/fixed string prawidłowy wuraz/regular expression

Prawidłowy wuraz rěka tu rozšérjeny prawidłowny wuraz kaž grep -E. Informacija wo grep je [tu](#) (jenož jendželsce)

Regular expression means here extended regular expression as understood by grep -E. Information can be found [here](#).

Statistika -- Příklady -- Kontekst / Statistics -- Examples -- Context

Informacija/Information:

příklady/examples statistika/statistics linkow konteksta/Lines of Context

Teksty wubrać/Text Selection

Wobr. 1. Přistupowy formular za hornjoserbski tekstowy korpus 2001

Pjeć lét po zahajenju džěla na korpusu, potajkim w lěće 2001, spřistupni so prěnja wersija zjawnje na internetowej stronje Serbskeho instituta.

Přistupowy formular bě dwurěčny serbsko-jendželski a njebě tehdy ani estetisce wosebje naročny ani jara komfortabelny za wužiwane. Tehdyši staw wuwića kompjuteroweho kodērowanja słowjanskich pismikow po wšelakorych zasadach a kodowych stronach bě při tym wosebite wužadanje. Zo by so korpus wot zajimcow po cyłym swěće njewotwisnje wot wužiwaneho kodērowanskeho standarda wužiwać hodžał, wuwi jeho załožer a wobdžělar Edward Wornar za specifisce serbske pismiki z diakritiskimi znamješkami transkripciju, kotaž wuńdže ze 128 znamješkami koda ASCII. Pismiki z diakritiku rozpuščichu so na dwě znamješce – zakladny pismik z předchadzacym symbolom za hóčku (\check{c} = $\wedge c$), smužku (\acute{c} = $/c$) resp. nakónsu smužku pola \dot{l}/\ddot{L} ($\dot{l} = _l$). Tak wupadachu drje serbske teksty chětro njezwučene, za to pak na wšech kompjuterach jenak. K znazornjenju a wujasnenju poda so w interneće příklad za transkripciju.

Example for Text Encoding -- Příklad kodērowanja

Rjana _Lu [^] zica, sprawna, p [^] re/celna, mojich serbskich w/otcow kraj, mojich zb/o [^] znych sonow raj. Swjate su mi twoje hona.	Rjana Łužica, sprawna, przećelna, mojich serbskich wótcow kraj, mojich zbóźnych sonow raj. Swjate su mi twoje hona.
--	---

($_$ for lslash/Lslash, \wedge for caron, $\^$ for acute)

Kedžbu/Attention!

Hdyž jako "typ wuraza" wubjerječe "prawidłowny wuraz", ma třeška \wedge funkciju wosebiteho znamješka. Tutu funkciju hasnje backslash před třešku (\^): česki = \^c\^eski.

If you select "regular expression" from "type of expression", caron \wedge gets a special meaning. To turn off this meaning, type a backslash before caron (\^): česki = \^c\^eski.

Wobr. 2. Pokazka kodērowanja słowjanskich pismikow z diakritiskimi znamješkami

Kompjuterowa technika pak je so dale wuwiwała, w kodērowanju je so mjezynarodnje přesadžíł standard Unicode, kotryž wobsahuje tež wosebite pismiki słowjanskich rěcow. Tohodla dotalny přistup k hornjoserbskemu tekstowemu korpusej nowym móžnosćam po lětach wjace njewotpowědowaše. K tomu příndže fakt, zo je wotrjad za delnjoserbske slědženja Serbskeho instituta delnjoserbski

digitalny korpus kónc lěta 2010 spřistupnił w spodobnej a za wužiwarja přijomnej formje na stronje www.dolnoserbski.de a zdobom na zakladze kooperacije z Institutom za Česki narodny korpus (ÚČNK) na tamnišej stronje www.korpus.cz z přidatnymi móžnosćemi za přepytowanje a rešeršowanje. Zo móžemy nětko tohorunja hornjoserbski tekstowy korpus na tutej stronje a ze samsnymi móžnosćemi wužiwać, za to mamy so kooperaciskim počaham a sobudžělu wjacorych partnerow džakować. Kolegaj z Choćebuskeho wotrjada Serbskeho instituta Fabian Kaulfürst a Marcin Szczepański posrědkowaštaj kontakt a zhromadne džělo z Praskim ÚČNK a pomhaštaj formu podawanja tekstow a trěbnych informacijow wo nich zjednotnić. Michal Křen z Praskeho instituta postara so mjez druhim wo segmentowanje běžnych tekstow na sady a wo jich přihotowanje za wšelake přepytowanske móžnosće, na př. za analyzowanje slovných skupin (kolokacijow). Zjednorjeny přistup za njelinguistow, kaž poskića so wón pod www.dolnoserbski.de za delnjoserbski korpus, tuchwilu za hornjoserbski hišće móžny njeje, za to dyrbja so hišće finacialne srédko a programowar namakać.

Žórła korpusa a wosebitosće tekstow

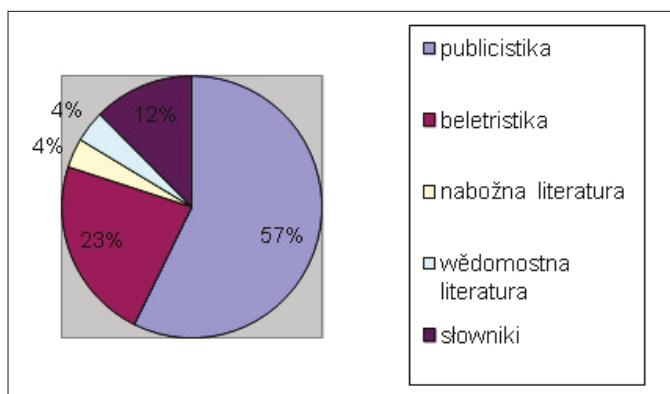
Džakowano zrěčenjam z Ludowym nakładnistwom Domowina w Budyšinje, w kotrymž wuchadža wjetšina publikacijow w hornjoserbskej rěči, a z Rěčnym centrumom WITAJ – to je wotrjad Domowiny, kotryž mjez druhim wudawa šulske wučbnicy a druhe wučbne srédko – smy móhli za rešeršowanje spřistupnić wobšérnu zběrku aktualnych tekstow – nowinow, časopisow a knihow. Při tym ma so wězo wobkedažowanje awtorskich prawow zaručić. Tohodla je maksimalna wulkosć pokazowanego konteksta pytaneho słowa wobmjezowana na 100 tokenow. Najwjetši džél tekstow za korpus pak je so z pomocu wědomostno-techniskeho personala Serbskeho instituta zaskenował a wobdžělał z pismo spóznawacymi OCR-programami. Dokelž njejsu so wuslědki tuteje procedury njedosahaceho personala dla w dosahacej měrje korigowali, njemóža so bohužel w tekstach korpusa zmylki wuzamknyc, za korektne citowanje je trjeba sahać po original. Tu čaka nas w přichodže hišće wjèle korekturneho džěla, tola tuchwilu ma hišće prioritu kwantitatiwny přirost korpusa.

Wěsty problem za linguistiske korpusowe slědženje je fakt, zo njejsu citowane pasaže w druhich rěčach, mjez druhim tež w delnjoserbščinje a němčinje, wosebje markěrowane. Za serbskeho wužiwarja abo dobreho znajerja serbščiny pak je poprawom lochko spóznać, hač jedna so wo hornjoserbščinu abo hinašu rěč.

Mjeńši džél tekstow, předewšém z 19. lětstotka, předleží w historiskim prawopisu (na př. pjeć lětnikow časopisa „Serbski hospodar“) – džensnišemu š wotpowěduje tu na př. *sch* (*mysch* město *myš*), za *č/č* pisa so *cž/cž* (*cžakacž* město *čakač*), za *s/z* pisa so *β/s* (*βasy* město *sazy*). Pisanje *kh* za džensniše *h* na spočatku morfemow a mjechke ř pak namakatej so tež hišce w tekstach nastatych w 20. lětstotku do lěta 1945. Na internetnej stronje Serbskeho instituta smy wo tym zaměstnili nadrobnu informaci, kotař móže wužiwarzej pomhać wšitke příklady za swoje naprašowanje namakać, hačrunjež jewja so prawopisne warianty.

W běhu lět je Hornjoserbski tekstowy korpus dosć nahladnje rozrostł: Tuchwilu je w nim 384 datajow wšelakeho razu a wšelakeje wulkosće, dohromady je to wokoło 44 milionow „tokenow“, potajkim jednotliwych separatnych słownych formow¹. Dokelž liča jako tokeny tež w tekscie wustupowace ličby a nimo toho kózde interpunkciske znamješko, je w korpusu trochu mjenje słowow hač tokenow (ca. 36 milionow).

Teksty hornjoserbskeho korpusa slúšeja do wšelakich kategorijow: Najwjetši je podžél publicistiki (57 %) a beletristiky (23 %), mjenje je nabožnych (4 %) a wědomostnych (4 %) tekstow, k tomu přińdu někotre słowniki a rjad terminologijow za jednotliwe šulske předmjety (12 %)².



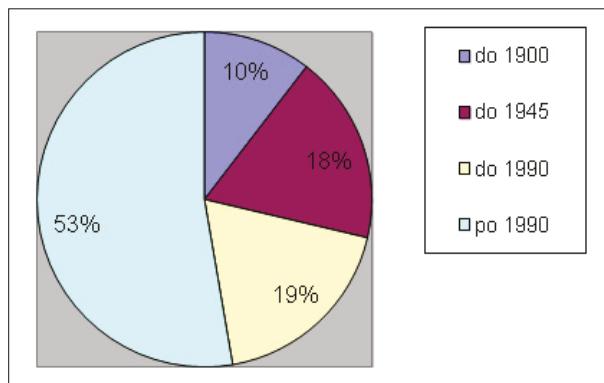
Wobr. 3. Podžél tekstowych družin na korpusu

Najstarše teksty sahaja hač do prěnjeje połojojcy 19. lětstotka, su to spisy Handrija Zejlerja a basnje Rudolfa Mjenja w nowowudačach z 20. lětstotka a lětniki „Časopisa Maćicy Serbskeje“ wot lěta 1848, najmłódše su „Serbske Nowiny“

¹ Zestajane časowe formy kaž na př. perfekt *sym spěwał* liča jako dwě słowje.

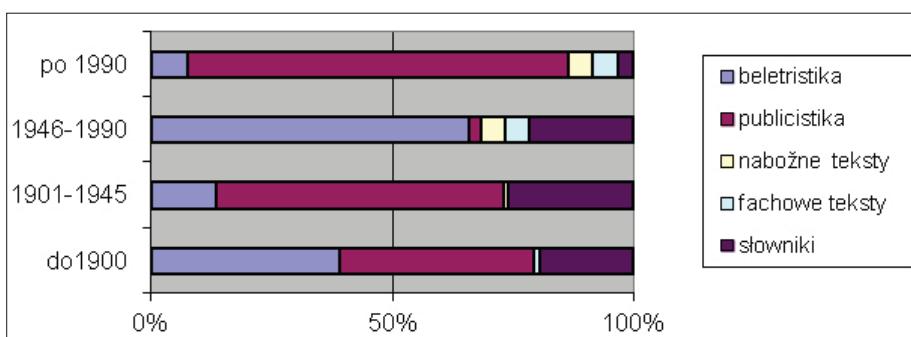
² Procentualne podžèle su so wuličili na zakladźe ličby tokenow (hlej horjeka).

a časopis „Katolski Posoł” z lěta 2010. Podźel jednotliwych časowych dobow je wšelaki: Najwjace mamy modernych tekstow z časa po přewróce 1989/90 (54 %). Z 19. lětstotka pochadza 10 %, z prěnjeje połojcy 20. lětstotka hač do 1945 je jich 18 % a z lět mjez 1945 a 1990 19 % – tak reprezentuje hornjoserbski tekstowy korpus z nimale třomi štvörčinami tekstow z časa po Druhej světovéj wójnje předewšěm rěč přitomnosće, tola wón dowola we wěstej mérje tež diachroniski přistup.



Wobr. 4. Podźel tekstow ze wšelakich dobow

Hdyž wobhladamy sej rozdźelenje tekstowych družin na jednotliwe časowe wotrězki, pytnjemy, zo njeje jich podźel přeco jenaki. Při dalšim rozšerjenju korpusa budže so wosebje na wurunanje disproporcijow mjez wšelakimi tekstowymi typami a časowymi dobam džiwać dyrbejeć, najtrěbniše je wudo-społnenje korpusa za druhu połojcu 20. lětstotka ze zběrku publicistiky.



Wobr. 5. Podźel tekstowych družin po časowych dobach

Dokelž so hornjoserbski tekstowy korpus běžnje wudospołnja, dyrbi so rjec, zo njejedna so wo tak mjenowany referenčny korpus, to rěka wo statiski korpus,

z kotrehož móža so konstantne statistiske daty dobywać. Wuhódnoćenja wotbłyščuja jenož aktualny staw w teksthach korpusa.

Přistup k hornjoserbskemu tekstowemu korpusej

HOrnjoserbski Tekstowy KOrpus, skrótka HOTKO, je zaměstnjeny na stronje Serbskeho instituta pod menijowym dypkom *online-publikacie*. Za serbskich wužiwarjow smy přihotowali nadrobnu dokumentaciju a pomocne informacie w hornjoserbskej rěči, kotrež namakače, hdyž nakliknjeće jednotliwe dypki pod krótkim zawodnym tekstem.

Wobr. 6. Přistup k HoTKo na stronje <http://www.serbski-institut.de/cms/os/48/hornjoserbski>

Dokelž zmóžnja so přeptytowanje hornjoserbskeho teksthoveho korpusa přez kooperaciju z Institutom za Česki narodny korpus na Filozofiskej fakulce Karloweje uniwersity w Praze (www.korpus.cz), dyrbjia sej wužiwarjo na jeho stronach wosobinske wužiwerske konto załožić. Za tutu proceduru namakaja so na mjenowanej internetowej stronje Serbskeho instituta wotpowědne serbskoréčne wujasnenja (menijowy dypk: přistup ke korpusej).

Štóż je sej na te wašnje přistup zarjadował, móže z pomocu wotprašowan-skeho programa Českého narodneho korpusa NoSketchEngine za wustupowanjom wěstych słowow w zapřijatých teksthach pytać – při tym namakaja so awtomatisce konkordancy za słowa, jich formy abo kombinacije. Koděrowane su tež metainformacie wo žórlach: Podaća wo awtorje, titlu, městnje a času wuchadženja móža so jako skrótšenka na lěwym boku abo tež dokladnišo

we wosebitym woknješku pokazować. Tež šerši kontekst hač do 100 słowow hodži so pokazać.

The screenshot shows the NoSketchEngine interface with the following details:

- User:** wölka
- Corpus:** hotk
- Description:** Hornjoserbský textový korpus, verze 1 z d. 3. 2013
- Size:** 44,367,372 positions
- Hits:** 47
- Search Query:** Hits: 47 i.p.m.: 1.06 (related to the whole corpus) | ARF: 17
- Results:**
 - Černý1**: bě to , stož předy we nas wědzechu ; lědma **rěčespytني** něsto wo naſej stowjanskéj prastarej rěci spomnichu . Ale ſto je Prěni , kži na nju dźiwač počaču , njebeču **rěčespytني** ménja po čornej pjeršći , na kotrejž ſej holanscy burja
 - Grojkt1**: , kotaře je drži pomjenovaná po Černym abo kaž držy **rěčespytني** ménja po čornej pjeršći , na kotrejž ſej holanscy burja
 - SSP1**: ! Zolobew a pod . Što ménja držy ? Redaktorjo a **rěčespytني** ? P . S . : Mjez Ukrainsjanami su tež
 - Lp95_1**: ita k wobdžělňanom sorabiča-slawicu w najšeršim zmysle , historikario , **rěčespytني** , kži bychmy wočakawac mohl , ale přírodnědny . Jako
 - Lp95_1**: aktualne za dzenišni rěčespyt . Młodogrammatikarjo biehu nimale wuwazujeń němczy **rěčespytني** . Najznačne mjena mjez Indoeuropštani ſez , germanistani ſu :
 - R1990**: , wobšerna a popularna biografija pobrachowauč , to njezaučauču jenož **rěčespytني** , ale tež kulturni stawiznjarjo a stawiznjarjo ſoyta - bě
 - R1990**: tro daſti studenca , kži su pozdiſe skutkowali jaſci sorabitisci **rěčespytني** : Pawel Vr̄t , Hans Holm Bleifeld a Arnulf Schröder
 - R1991**: Moskowskich fachowcow . Na předſteženju serbičskich dialektow ſu wo wobdžili **rěčespytني** z Pólskeje , Českaje a Sowjetiskej zvijazka . Tutón bjezpoſredni
 - R1992**: žonow njeje to hač dołat híſce pytnyl , ani naši **rěčespytني** . Hewak bychu ſej wžeo híza dawno blowu ſamalit a
 - R1993**: stron Institucionalizowanego rěčespyt . Pomär wišak je dwuſtronski . Tež **rěčespytني** Serbského Instituta trjebaja w swojim powatošanskim džěle radu a pomoc
 - R1993**: Zolobew a pod . Što ménja držy ? Redaktorjo a **rěčespytني** ? P . S . : Mjez Ukrainsjanami su tež
 - R1994**: wobšte - jacy ſtyki wožišči a nowe zwiski paviač . Chorvatcy **rěčespytني** ſu weseſe na wobſtajnej wumění literatury na polu filologije z
 - R1994**: dyskeho Serbského Instituta měli někotři serbičy a polcy wídmostnicy (**rěčespytني** a réčni sociologoj) wuwid ſerb- ſkeje rěci přeptytowac .
 - R1994**: w serbičinje pol . 1991 dale ſlo . Serbičy **rěčespytني** ſo z tutym wuwidom rozstajaja , za zjawnost tuchwilu hótnje
 - R1995**: a w kaſubskjej rěci . Posledni hótnoca polcy a kaſubscy **rěčespytني** jako nastawcu spisowni rěč . Přinoški na konferencji biehu wěnowane
 - R1995**: a HSKR ſu (hač na jednoho) wuity serbičy **rěčespytني** , někotři lektoriyo , redaktoriyo , wüčerjo a daſli multiklikatorjo
 - R1996**: to tuchwilu w DSR praktike . Wuznawaja da ſo ſoja **rěčespytني** -fachowcy ſamí des we wšich tyd komplikowanych , mjez ſobu
 - R1997**: Stejirny dirje před nowej tendencji w serbičinje , kotruž nam **rěčespytني** zawěše bőrje wopodstawnia . Možalk Léto 1999 w SLA Ž
 - R1997**: zjawnosći a jeho rôlu při zawięſzeniu zakładow narodowej eksistencji ſu **rěčespytني** a stawiznjarjo w dalaſej měreje přeſtedžili a pokazal . Mjenje
 - R1998**: hi ſu dánškim kniesištom dn wileśnie role znamenča . Prěni **rěčespytني** z hornjoserbsku w XIX... ſtmiařu ſie ſtrukti w zanjesjenych wsach

Wobr. 7. Konkordanca zdobyta w HoTKo z rozšerjenym podačom žorla

W tutych konkordancach płaća pytanske a statistiske móžnosće programa NoSketchEngine: Hodži so na př. přeptytować, kak husto wěste ſłowa abo ſłowne formy wustupuja a w kajkim susodſtwje ſo wosebje jewja, móže ſo tež zwěſćić, hač ſu za wěſtých awtorow typiske, na wěste družiny tekſtow abo snano na wěſtu časowu dobu wobmjezowane. Program zmóžnja tež pytanje ſłowow w definowanych kontekſtach a dowoli indiwiuelny wubér, w kotrych tekſtach ma ſo pytać, z pomocu definowanja wosobinskich subkorpusow.

Hornjoserbski korpus njeje hiſće lematizowany a gramatisce anotērowany – to rěka, zo njeſu wšelake ſłowne formy jednotnemu heslu přirjadowane kaž w ſłowniku (na př. *rukū*, *ruče*, *rukow*, *rukomaj* k heslu *ruka*) a njeſu po ſłownych družinach abo gramatiskich formach analyzowane. To wobmjezuje pytanske móžnosće wosebje za rěčespytne praſenja z wobłuka ſyntax a morfologije. Za namakanje po móžnosći wšich formow někajkeho pytaneho ſłowa móža ſej wužiwarjo pomhać z tak mjenowanymi regularnymi wurazami (jendź. regular expressions), w kotrych wužiwaja ſo znamješka, kotrež funguja jako naměſtniki za wšelake warianty – za

to wobsteja wšelake w nadrobnosćach so wotchilace standardy. Za HoTKo płaće zasady, kotrež bazuja wězo na zasadach Českého narodneho korpusa, su w lisćinje na stronje Serbskeho instituta pod dypkom „regularne wurazy” wopisane.

Wězo njesmědža so při wužiwaniu ženje zabyć wěste wobmjezowanja za wuslědki rešeršow. Prěnje tajke wobmjezowanje rezultuje z toho, zo nimamy korpus wšich hornjoserbskich tekstow. Hdyž potajkim někajku formu njenamakamy, rěka to jenož, zo njeje wona w korpusu. Dopokaz, zo wona njeeksistuje, to hišće njeje. Druhe wobmjezowanje zaleži na tym, zo móža teksty korpusa nimo prostych OCR-zmylkow tež rozšérjene rěčne zmylki dokumentować – hranica mjez zmylkom a nowej, so šérjacej formu tež za rěčespytnika druhdy cyle wótra njeje.

Dalše informaciske srédko wo hornjoserbskej rěči w interneće

Přestajeny hornjoserbski tekstowy korpus dyrbi so widźeć w kontekscé dalších projektow Budyskeho rěčespytného wotrjada Serbskeho instituta. Čežišco tworja tu prašenja słowoskłada a leksikografije. Centralny zaměr předstaja projekt wobšérneho noweho němsko-hornjoserbskeho słownika, kotryž tuchwilu w našim wotrjedze koncipujemy – z tym reagujemy na potrjebu serbskeje rěčneje praksy, kotaž žada sej wjac hač dwaj lětdžesatkaj po wudaću poslednjeho tajkeho kompendija (Jenč, Michałk & Šerakowa, 1989–1991) nowy a metodologisce daleuwuwity pomocny grat. Planowany słownik je primarnje za digitalne wužiwanie w interneće mysleny. Njerěka pak to, zo njebudže so z njeho sekundarnje tež číšcany słownik generērować dać. Technologisce budže so wón zepěrać na nazhonjenja wotrjada za delnjoserbske slědženje, a tež koncepcionelne matej wobaj słownikaj mjezsobu kompatibelnej być. Tole wšak je – hladajo na hornjoserbštinu – tuchwilu hišće hudźba přichoda. Zrealizowane su porno tomu hižo wěste předdźěla.

Projekt *Němsko-hornjoserbskeho słownika noweje leksiki* wobdzělany wot Helmuta Jenča, Anje Pohončoweje a Jany Šołćineje (Jenč, Pohončowa & Šołćina, 2006), wobsahowacy někak 12000 hesłow, drje njeje ani za internet koncipowany ani w nim přistupny, jako zběrka, registrowaca nowu leksiku po wudaću němsko-hornjoserbskeho słownika 1989–1991, pak ma so wón jako krok po puću k planowanemu internetowemu słownikej widźeć.

Prěni z digitalnych, online přistupnych poskitkow SI za hornjoserbštinu, kiž chcu tu mjenować, je *Hornjoserbski frazeologiski słownik* w interneće. Wón je nastał na zakladźe hornjoserbsko-němsko-ruskeho frazeologiskeho słownika,

kotryž smój hromadže z Anatolijom Iwčenku w lěče 2004 wudałoj (Ivčenko & Wölke, 2004). Internetna wersija, kotař je wot 2005 přistupna (<http://www.serbski-institut.de/cms/de/50/Obersorbisches-phraseologisches-Woerterbuch>), wobmjezuje so na hornjoserbšćinu a němčinu, dowoli pak za to wobšerniše pytanske móžnosće wuchadžejo z wobeju rěčow. Nimo toho so tuta digitalna wersija běžnje z přidatnymi frazeologizmami wudospołnja.

Specialnu leksikografisku zbérku předstaja datowa banka geografiskich mjenow w hornjoserbšćinje a němčinje (Geografiske mjená hornjoserbsce, n.d.; <http://www.serbski-institut.de/cms/os/396/Geografiske-mjena-hornjoserbsce>). Wona je nastala w zhromadnym dźěle z Rěčnym centrumom WITAJ, hdźež nastawaja serbske wučbnicy, mjez nimi tež tajke za geografiju. Tuchwilu su w datowej bance předewšem zezbérane tak mjenowane eksonomy (něhdźe 2000), potajkim geografiske mjená za objekty zwonka Serbow, tola planujemy ju rozšírić tež wo hornjoserbske geografiske mjená z Łužicy. Wotprašowanje datow je móžne wuchadžejo z němčiny, ale tež wuchadžejo z hornjoserbšćiny. Systematiske wobdžělanje tutoho wosebiteho dźěla słowoskłada w cyłku je zakład za jeho po móžnosći dospołne a zdobom konsekwentne a we sebi konsistentne předstajenje w planowanym němsko-hornjoserbskim słowniku a služi na druhim boku stabilizacji normy spisowneje rěče.

Zwonka rěčespytneho wotrjada je so w nadawku Serbskeho instituta zdžěła zbérka w interneće přistupnych hornjoserbskich dwurěčnych słownikow SERDIS – Serbske digitalne słowniki. SERDIS nastala na iniciativu a z koordinaciju přez Franca Šena w zhromadnym dźěle Serbskeho instituta w Heidelbergu skutkowacym neurobiologom Jurjom Brankačkom a ukrainskim programowarjom Vladimirom Kukušku. Online přistupne, programowane w Java®, namakaja so tam digitalne wersije hornjoserbsko-němskeju słownikow Křesćana Bohuwěra Pfula (Pful, 1866) a Jurja Krala (Kral, 1927), hornjoserbsko-ruskeho słownika Konstantina Trofimoviča (Trofimovič, 1974) a dwě dalšej mjeńšej leksikografiskej zbérce. W SERDIS móže so principielnje w dwěmaj směromaj pytać – tola pytanje wuchadžejo z ciloweje rěče je skerje wobmjezowane dla přesnadneje hłubokosće a nadrobnosće analyzy słownikowych artiklow. Za dalewuviće tutoho online-poskitka by derje było, so orientować na metodach, kiž su so nałożowali za wotpowědny delnjoserbski poskitk.

Hornjoserbski tekstowy korpus twori ważny materialowy zaklad za wšę leksikografiske dźěla rěčespytneho wotrjada Serbskeho instituta. Intensiwnje je so wón hižo wužiwał za wšitke tři runje mjenowane hižo zrealizowane pro-

jecky: słownik noweje leksiki (Jenč et al., 2006), frazeologiski słownik (Ivčenko & Wölke, 2004) a datowu banku geografiskich mjenow, nimo toho tež zwonka SI za jendželsko-hornjoserbski słownik Měrćina Straucha a Edwarda Wornarja (Wornar & Strauch, 2007). Porno tradicionalnym metodam leksikografije před dobu kompjutera – jako dźělaše so ze statiskimi papjerjanymi kartotekami – mamy z tym wulke lěpšiny. Hladajo na wobjim (tuchwilu 36 mio słowow porno 1 mio kartkow za dwuzwajzkowy němsko-hornjoserbski słownik Jenča et al. 1989–1991) je digitalny korpus wo wjele spušćomniše wuchadžišćo. Za digitalny korpus steja k dispoziciji wjele diferencowaniše móžnosće analyzy, na př. po frekwency a konteksće. Nimo toho njeje digitalny korpus lokalnje wjazany na městno kartoteki, ale je přistupny zjawnje po cyłym swěće, a to nic jenož za leksikografiske, ale tohorunja za druhe rěčespytné předewzaća, a z přiběracym mnóstwom zapřijatych tekstow tež přeco lěpje za rešerše literaturowědneho abo stawizniskeho razu.

Bibliography

- Dolnoserbski. (n.d.). Retrieved December 19, 2013, from www.dolnoserbski.de
- Geografiske mjena hornjoserbsce. (n.d.). Retrieved from <http://www.serbski-institut.de/cms/os/396/Geografiske-mjena-hornjoserbsce>
- Ivčenko, A., & Wölke, S. (2004). *Hornjoserbski frazeologiski słownik* [Obersorbisches phraseologisches Wörterbuch; Верхнелужицкий фразеологический словарь]. Budyšin: Ludowe nakładnistwo Domowina. Retrieved from <http://www.serbski-institut.de/cms/de/50/Obersorbisches-phraseologisches-Woerterbuch>
- Jenč, H., Michałk, F., & Šerakowa, I. (1989–1991). *Němsko-hornjoserbski słownik* (Vol. 1–2). Budyšin: Ludowe nakładnistwo Domowina.
- Jenč, H., Pohončowa, A., & Šołćina, J. (2006). *Němsko-hornjoserbski słownik noweje leksiki*. Budyšin: Ludowe nakładnistwo Domowina.
- Kral, J. (1927). *Serbsko-němski Słownik hornjołužiskeje rěče* [Wendisch-deutsches Wörterbuch der oberlausitzer Sprache]. Budyšin: Maćica Serbska.
- Pful, K. B. (1866). *Łužiski serbski słownik: Lausitzisch Wendisches Wörterbuch*. Budyšin: Maćica Serbska.
- Šen, F. (2013). Sorabistika a nowe medije. In M. Milewska-Stawiany, & S. Wölkowa (Eds.), *Leksikologiske přinoški II: IV. seminar serbskeje słowotwórby a leksiki* [IV Seminarium Słowotwórstwa i Słownictwa Łużyckiego] : Uniwersytet Gdańsk. Serbski institut 31.5. – 1.6.2012 (pp. 131–141). Budyšin: Serbski institut.

- Šołćina, J., & Wornar, E. (1996). Čehodla trjebamy jednorěčny hornjoserbski słownik? In E. E. Siatkowska, & J. Molas (Eds.), *Sprawy łużyckie w ich słowiańskich kontekstach* (pp. 15–22). Warszawa: Instytut Filologii Słowiańskiej UW.
- Trofimovič, K. (1974). *Hornjoserbsko-ruski słownik [Верхнелужицко-русский словарь]*. Budyšin: Ludowe nakładnistwo Domowina.
- Wölkowa, S. (2013). Hornjoserbski tekstowy korpus w nowej formje. *Serbska Šula*, 66(2), 44–47.
- Wornar, E., & Strauch, M. (2007). *Jendželsko-hornjoserbski šulski słownik* [English-Upper Sorbian Learner's Dictionary]. Budyšin: Ludowe nakładnistwo Domowina.

Bibliography (transliteration)

- Dolnoserbski. (n.d.). Retrieved December 19, 2013, from www.dolnoserbski.de
- Geografiske mjena hornjoserbsce. (n.d.). Retrieved from <http://www.serbski-institut.de/cms/os/396/Geografiske-mjena-hornjoserbsce>
- Ivčenko, A., & Wölke, S. (2004). *Hornjoserbski frazeologiski słownik* [Obersorbisches phrasologisches Wörterbuch; Verkhneluzhitskij frazeologicheskiy slovar']. Budyšin: Ludowe nakładnistwo Domowina. Retrieved from <http://www.serbski-institut.de/cms/de/50/Obersorbisches-phraseologisches-Woerterbuch>.
- Jenč, H., Michałk, F., & Šerakowa, I. (1989–1991). *Němsko-hornjoserbski słownik* (Vol. 1–2). Budyšin: Ludowe nakładnistwo Domowina.
- Jenč, H., Pohončowa, A., & Sołćina, J. (2006). *Němsko-hornjoserbski słownik noweje leksiki*. Budyšin: Ludowe nakładnistwo Domowina.
- Kral, J. (1927). *Serbsko-němski Słownik hornjołužiskeje rěče* [Wendisch-deutsches Wörterbuch der oberlausitzer Sprache]. Budyšin: Maćica Serbska.
- Pful, K. B. (1866). *Łužiski serbski słownik: Lausitzisch Wendisches Wörterbuch*. Budyšin: Maćica Serbska.
- Šen, F. (2013). Sorabistika a nowe medije. In M. Milewska-Stawiany & S. Wölkowa (Eds.), *Leksikologiske přinoški II: IV. seminar serbskeje słowotwórby a leksiki* [IV Seminarium Słowotwórstwa i Słownictwa Łużyckiego]: Uniwersytet Gdańsk. Serbski institut 31.5. – 1.6.2012 (pp. 131–141). Budyšin: Serbski institut.
- Sołćina, J., & Wornar, E. (1996). Čehodla trjebamy jednorěčny hornjoserbski słownik? In E. E. Siatkowska & J. Molas (Eds.), *Sprawy łużyckie w ich słowiańskich kontekstach* (pp. 15–22). Warszawa: Instytut Filologii Słowiańskiej UW.
- Trofimovič, K. (1974). *Hornjoserbsko-ruski słownik* [Verkhneluzhitsko-russkiy slovar']. Budyšin: Ludowe nakładnistwo Domowina.
- Wölkowa, S. (2013). Hornjoserbski tekstowy korpus w nowej formje. *Serbska Šula*, 66(2), 44–47.
- Wornar, E., & Strauch, M. (2007). *Jendželsko-hornjoserbski šulski słownik* [English-Upper Sorbian Learner's Dictionary]. Budyšin: Ludowe nakładnistwo Domowina.

The Upper Sorbian text corpus and further sources of information with regard to Upper Sorbian in the Internet

Summary

In the present era of globalisation and the omnipresence of the Internet, Sorbian linguistics faces new challenges along the lines “What is not in the Internet, does not exist” The demand for digital sources of information with regard to Upper and Lower Sorbian and those accessible online as working tools and reference points for language practice and as a source for academic research increases. As a result of this ongoing development, the *Foundation for the Sorbian People* established a workgroup called “Sorbian in the new media” at the end of 2012, which has pointed out the creation of an online German-Upper Sorbian dictionary as the major task in this field of activities. The focus of this article, however, is the Upper-Sorbian text corpus HoTKo, which has been created by the *Sorbian Institute* and which has been made available in co-operation with the Institute of the Czech National Corpus at the Charles University in Prague. The article presents the history and development of the corpus, its extent and shape as well as its link to or incorporation into further planned digital projects of the *Sorbian Institute* with regard to the Upper Sorbian language.

Keywords: computational lexicography; corpus linguistics; digitalization; text corpus; Upper Sorbian language

Słowa kluczowe: digitalizacja; język górnoużycki; korpus językowy; leksykografia komputerowa; lingwistyka korpusowa