

Magyar nyelvű néprajzi keresőrendszer

Zsibrita János¹, Vincze Veronika²

¹ Szegedi Tudományegyetem, Informatikai Tanszékcsoport
zsibrita@inf.u-szeged.hu

² MTA-SZTE Mesterséges Intelligencia Kutatócsoport
vinczev@inf.u-szeged.hu

Kivonat: A cikkben bemutatjuk Java-alapú keresőrendszerünket, mely különféle néprajzi szövegekben – hiedelmekben, táltosszövegekben és népmesékben – egész mondatos kereséseket tesz lehetővé. A rendszer azokat a dokumentumokat adja vissza, ahol a keresett ige és annak vonzatai a keresőkifejezésben megadott nyelvtani viszonyban állnak egymással. A rendszer alapjait a magyar nyelv morfológiai és szintaktikai elemző moduljai jelentik. A kereső a teljes egyezések mellett részlegesen egyező találatokat is képes visszaadni, illetve a találatok grafikus megjelenítésére is van mód.

1 Bevezetés

A MASZEKER projekt keretében az angol nyelvű szabadalmi keresőrendszer mellett [1] egy magyar nyelvű néprajzi szövegeken működő keresőrendszer is elkészült. A kereső célja, hogy különféle néprajzi dokumentumokban egész mondatos kereséseket hajtson végre, azaz olyan dokumentumokat ad vissza, ahol a keresett ige és vonzatai a keresőkifejezésben megadott viszonyban állnak egymással. A keresőrendszer teljes egészében Javában implementált, így platformfüggetlenül használható.

2 A keresőrendszer

A keresőrendszer alapjait a magyar nyelv morfológiai és szintaktikai (dependencia)elemző [3, 4] jelenti, amely meghatározza a szövegben levő szavak szófaját és a köztük levő nyelvtani kapcsolatokat. A keresés háttérül szolgáló adatbázis magyar nyelvű hiedelmeket, táltosszövegeket, illetve meséket tartalmaz, összesen kb. 1,4 millió szövegszóból áll [2]. A néprajzi szövegek hatékony nyelvi elemzéséhez szükségesnek bizonyult a népies, illetve régies helyesírású szavak mai helyesírás szerinti átírása, így első lépésben ezek cseréje történt meg egy, a magyar nyelvbe integrált szótáralapú hibajavító modul segítségével.

A keresés során a keresőmondatot először dependenciaelemzésnek vetjük alá, majd a megtalált grammatikai relációknak megfelelő illeszkedéseket keresünk a szövegekben: a keresőkifejezés igéjének összes előfordulását megkeressük, majd megnézzük, hogy az adott mondatokban levő igei bővítmények lemmája egyezik-e a

keresőkifejezésben szereplő bővítmények lemmájával, illetve hogy ugyanolyan grammatikai reláció van-e köztük (pl. mindkét esetben az ige tárgyáról van-e szó). Amennyiben igen, teljes értékű találatként adja vissza a rendszer az adott mondatot, illetve dokumentumot. Ha csak részleges egyezést tapasztalunk, például az ige egyik bővítménye egyezik, de a másik eltér, akkor azt részleges találatként jeleníti meg a rendszer. Lehetőség nyílik arra is, hogy csak az ige egyezését vizsgáljuk. A keresés során választható, mely részkorpusz szövegeiben kívánunk keresni, illetve a találatok szintaktikai reprezentációjának grafikus megjelenítésére is van lehetőség.

2.1 A keresés során használt korpusz jellemzői

A demonstráció egy magyar néprajzi korpuszon történik, aminek a konszolidálása, azaz a benne szereplő népies írásképű szavaknak a ma szokásos alakra alakítása (az eredeti íráskép megtartása mellett) már korábban megtörtént. A hiedelem- és táltosszövegek a Néprajzi Múzeumnak a történelmi Magyarországról származó gyűjtéséből származnak, korabeli feljegyzések alapján gépelték be a kutatók. A mese korpusz néhány ingyenes internetes forrásról történő gyűjtés eredménye.

- Állatmesék (124 dokumentum)
- Formulamesék (20 dokumentum)
- Hazugságmesék (12 dokumentum)
- Legendamesék (55 dokumentum)
- Novellamesék (136 dokumentum)
- Rászedett ördög mesék (5 dokumentum)
- Rátótiádák (1 dokumentum)
- Tréfás mesék (11 dokumentum)
- Trufák és anekdoták (23 dokumentum)
- Tündérmesék (124 dokumentum)

A korpusz fontosabb adatai az 1. táblázatban láthatók.

1. táblázat: A néprajzi korpusz mérete.

Szövegtípus	Szövegek száma	Szavak száma
Népi hiedelem	2704	65807
Táltosszövegek	432	44021
Népmesék	505	633047
Összesen	3641	742875

2.2 A keresőkifejezés kialakítása

A keresés megszorított nyelvezetű keresőkifejezések alapján történik. A keresőkifejezés egy **egy tagmondatból** álló, **egy igét** tartalmazó (egyszerű) mondat. Az ige bővítményeként különféle **főnevek** szerepelhetnek különféle esetragokkal. A

határozószavak használata nem megengedett. **Tagadást** és **modalitást** jelző elemek használatát sem engedjük meg.

Néhány jólformált keresőkifejezés:

- *Foggal születik a táltos.*
- *A róka kergeti a nyulat.*
- *A lány körbefutja a házat.*

Néhány rosszulformált keresőkifejezés:

- *A vörös róka kergette tegnap a nyulat.*
- *A lány hirtelen előveszi és megeszi az almát.*
- *A róka nem eszi meg a nyulat.*
- *A róka megeheti a nyulat.*

Alárendelő mellékmondatok, illetve **mellérendelő tagmondatok** használata sem megengedett, ilyenkor több egymás utáni keresőmondatot kell alkalmazni.

- *A lány körbefutja a házat, és megeszi az almát. -> A lány körbefutja a házat. A lány megeszi az almát.*

Természetesen az alany pontos meghatározása nélkül is lehetséges keresni, ilyenkor csak az ige egyéb vonzatait tüntetjük fel a keresőkifejezésben:

- *Foggal születik.*
- *Bikával küzd.*

2.3 A keresőrendszer korlátai

A magyar nyelv grammatikai sajátosságaiból adódóan azonban problémát jelentenek a névmási referenciák, illetőleg az olyan mondatok, ahol a bővítményeket nem fejezzük ki külön szóval. Lásd az alábbi szövegrészletet:

Volt egyszer egy király_i, aki_i olyan gyönyörű templomot építtetett, hogy közel s távolban nem találta senki párját. Egy szép napon azután messze távolból jött egy vándor_j, és (ő_j) hosszan bámulta a csodaszép épületet. A király_i odament hozzá_j, és (ő_j) megkérdezte tőle_j, hogy tetszik neki_j a templom.

A szövegben azonos indexszel vannak jelölve az azonos egyedre utaló szavak, a zárójelbe tett névmások pedig az eredeti szövegben nem szerepelnek. Azonban legjobb tudomásunk szerint a magyar nyelvre nem áll rendelkezésre olyan automatikus elemző, amely az ehhez hasonló eseteket automatikusan azonosítaná, így jelenleg ez a

szöveg nem jelenik meg találatként az „a király odamegy a vándorhoz” keresőkifejezésre.

3 Az eredmény bemutatása

A keresés gomb megnyomásával elindul a keresés és az illesztés algoritmus. A keresési algoritmus lefutása után megjelenik a keresőkifejezés elemzett fastruktúrája. Ezek után pedig a keresésnek megfelelő dokumentumokból készített találati lista.

Ha bármely találati listában szereplő dokumentum teljes tartalmát meg szeretnénk tekinteni, elég a dokumentum sorára kattintanunk. Ekkor egy új ablak nyílik meg, a teljes dokumentummal.

Keresőmondat

Mesék

- ☒ allatmesek
- ☒ hazugsagok
- ☒ legendák
- ☒ novellák
- ☒ rászédett
- ☒ rotatoda
- ☒ trefas_mes
- ☒ trufak_es_i
- ☒ tundermes
- ☒ Egyeb
- ☒ Találatok
- ☒ Hiedelmek

Keresés

415

AC Erdélyi szász népmesék

CATEGORY tundermesek

FILE mek.oszk.hu/060006693

FORRÁS az_aranymadar.txt

H 415

ID 415

K KAC

KFC A csodálatos fa

KW AZ ARANYMADÁR

MFC Újvárosi Kiadó

SZ 1979

EV 1979

Volt egyszer egy király, aki olyan gyönyörű templomot építtetett, hogy közel s távolban nem találta senki párját. Egy szép napon azután messze távolból jött egy vándor, és hosszan bámulta a csodaszép épületet. A király odament hozzá, és megkérdezte tőle, hogy tetszik neki a templom. A vándor így válaszolt:

- Ez a legszebb templom, amelyet valaha is láttam, csupán egyetlenegy dolog hiányzik belőle: az aranymadár, amelyik gyöngyöket hullat a csőréből, amikor énekel.
- A király erre megkérdezte tőle, hol található ez a madár.
- Azt nem tudom - felelte a vándor. - En is csak hírt hallottam!
- Ettől kezdve a királynak nem volt többé nyugalma, mert folyton-folyvást arra kellett gondolnia, hogyan is tehetné szert az aranymadárra. Aztán egy napon odajött hozzá a legidősebb fia, és így szólt:
- Atyám, én útra kelek, és megpróbálom megkeresni az aranymadarat.
- Megjött erre a király, legjobban lovát adta oda a fiának, és úgy engedte útjára. A fiú csakhamar egy erdőbe ért, és tüzet gyújtott. Alig lobbant fel a tűz lángja, odafutott hozzá egy róka, és jajgatni kezdett:
- Jaj, az isten hiede majd megveszt!
- Hát rakj tüzet és melegedj!
- mondta a királyfi, és azzal elővette az útravalóját. A róka újra megszólalt:
- Jaj, a gyömröm az éhségtől hogy korog!
- Hát keresd magadnak élelmet, és lakjál jól!
- szólt oda a királyfi, s erre a róka elszaladt.
- A királyfi felkerekedett és továbbment. Hamarosan feléte egész útravalóját, és rossz társaságba keveredett; először a lovát adta el, aztán eladósodott, és végül kénytelen volt elszegődni egy vendégházban szolgának.
- Kis idő múlva a második királyfi is útra kelet, hogy megkeresse az aranymadarat. Atyja neki is adott egy remek paripát, és alaposan feltárazta, de ez a fiú is ugyanúgy járt, akárcsak a bátyja.
- Mikor tüzet rakott az erdőben, odajött hozzá a róka, és elkezdett jajgatni:
- Jaj, az isten hiede majd megveszt!
- Jaj, jaj, a gyömröm éhen vesz!
- Hát rakj tüzet és melegedj!

431	Az ördög és a két leány	Magyar népmesék	Arany László	Móra	Budapest	1978	mek.oszk.hu/...
432	Az ördög meg a lány	Az ördög és a lány	Nagy Ilona	Akadémiai ki.	Budapest	1990	www.nepmes...
433	AZ ÖRDÖG HÁROM ARANY HAJSZÁLA	Grimm legszebb m.	Grimm, Vilhe	Móra Kiadó	Budapest	1965	mek.oszk.hu/...
434	A békakirály	Grimm legszebb m.	Grimm, Vilhe	Móra Kiadó	Budapest	1965	mek.oszk.hu/...
435	A BÉKA-KIRÁLYKISASSZONY	Többsincs királyfi é.	Benedek Elek	Móra	Budapest	1975	mek.oszk.hu/...
436	A BÉKA-KIRÁLYKISASSZONY	Elvarázolt madarak	Ilona László	Móra Kiadó	Budapest	1961	mek.oszk.hu/...

1. ábra. A találati lista egy megnyitott dokumentummal.

A megjelenő új ablakban a dokumentumra jellemző egyéb metainformációk is megjelennek, azaz annak kategóriája, az internetes forrás elérhetősége, a fájl neve, azonosítója, a kötet címe, kiadási helye és éve, a gyűjtő vagy a kötet szerkesztő neve:

AC
CATEGORY tundermesek
F
 www.nepmese.hu/index.php?option=com_mtree&Itemid=26
FILE bruncik_kiralyfi.txt
FORRÁS
H Budapest
ID 459
K Akadémiai Kiadó
KAC
KFC Rózsafiú és Tulipánleány
KW
MFC Bruncik királyfi
SZ Kovács Ágnes szerk.
ÉV 1987

Az elemzett keresőkifejezés megjelenítésére is van lehetőség, l.2. ábra.



2. ábra. Egy elemzett keresőkifejezés megjelenítve.

A keresés eredménye egy új ablakban jelenik meg, dokumentumcsoportok szerint rendezve, ahogyan az a 3. ábrán is látszik. A találati lista minden sora egy-egy dokumentumot reprezentál. Minden sor tartalmazza az adott dokumentum keresőkifejezésre illeszkedő mondatát, vagyis a releváns szövegrészt.

Találatok - jött egy felhő	
ID	HIEDELMEK
205	Mikor itt megtalálták föltették a toronyba és ha veszedelmes felhő jön ezzel harangozni...
ID	MESÉK
459	Alighogy helyet csinálnak, mintha egy fekete felhő jőne, annyi azördög, mint a riten a f...
486	Alighogy helyet csinálnak, mintha egy fekete felhő jönne!

3. ábra. A „jött egy felhő” keresőkifejezésre illeszkedő dokumentumok találati listája.

A találati lista egy tetszőleges elemére kattintva megjeleníthető a releváns mondat elemzése (l. 4. ábra). Így ellenőrizhető, hogy az algoritmus mi alapján végezte el az illesztést.

Alighogy helyet csinálnak, mintha egy fekete felhő jönne!									
	ROOT			CONJ			COORD		
		CONJ			CONJ			DET	
		OBJ			FUNCT			ATT	
								SUBJ	
								ATT	
Root-	Alighogy	helyet	csinálnak	,	mintha	egy	fekete	felhő	jönne !
	1	2	3	4	5	6	7	8	9
	alighogy	hely	csinál	,	mintha	egy	fekete	felhő	jön
									10
	$\bar{C}$	$\bar{N}$	$\bar{V}$	$\bar{,}$	$\bar{C}$	$\bar{T}$	$\bar{A}$	$\bar{N}$	$\bar{V}$
	-	-	-	-	-	-	-	-	-
	-	-	-	-	-	-	-	-	-

4. ábra. A találati lista egy elemének szintaktikai elemzése.

A néprajzi keresőrendszer egy népmesékben való keresést lehetővé tevő verziója kutatási célokra nyilvánosan elérhető a <http://maszeker.huminf.u-szeged.hu> honlapon.

Köszönetnyilvánítás

A kutatás – részben – a MASZEKER kódnevű projekt keretében a Nemzeti Fejlesztési Ügynökség támogatásával, illetve a futuriCT.hu nevű, TÁMOP-4.2.2.C-11/1/KONV-2012-0013 azonosítószámú projekt keretében az Európai Unió és az Európai Szociális Alap társfinanszírozása mellett valósult meg.

Hivatkozások

1. Szöts M., Csirik J., Gergely T., Karvalics L.: MASZEKER: projekt szemantikus keresőtechnológia kidolgozására. In: Tanács A., Vincze V. (szerk.): VII. Magyar Számítógépes Nyelvészeti Konferencia. Tudományegyetem, Szeged (2010) 159–167
2. Szöts, M., Darányi, S., Alexin, Z., Vincze, V., Almási, A.: Semantic processing of a Hungarian ethnographic corpus. In: Proceedings of the First International AMICUS Workshop on Automated Motif Discovery in Cultural Heritage and Scientific Communication Texts. Bécs, Ausztria (2010) 112–115
3. Zsibrita J., Vincze V., Farkas R.: Ismeretlen kifejezések és a szófaji egyértelműsítés. In: Tanács A., Vincze V. (szerk.): VII. Magyar Számítógépes Nyelvészeti Konferencia. Szegedi Tudományegyetem, Szeged (2010) 275–283
4. Zsibrita J., Vincze V., Farkas R.: magyarlanc 2.0: szintaktikai elemzés és felgyorsított szófaji egyértelműsítés. In: Tanács A., Vincze V. (szerk.): IX. Magyar Számítógépes Nyelvészeti Konferencia. Szegedi Tudományegyetem, Szeged (2013) 368–374