

ՀԱՄԸՆԴՀԱՆՈՒՐ ԿԱԽՎԱԾՈՒԹՅՈՒՆՆԵՐ ԵՎ ՀԱՅԵՐԵՆԻ ԾԱՌԱԴԱՐԱՆԸ¹

Մարատ Յավրումյան

Բանասիրական գիտությունների թեկնածու
ԵՊՀ, արաբագիտության ամբիոն
ՀՀ, Երևան, Ալեք Մանուկյան 1
Էլ. հասցե՝ myavrum@ysu.am

Աննա Դանիելյան

ԵՊՀ, արաբագիտության ամբիոն
ՀՀ, Երևան, Ալեք Մանուկյան 1
Էլ. հասցե՝ adanielyan@ysu.am
Հոդվածը ներկայացվել է 10.02.2020, գրախոսվել է 10.02.2020, ընդունվել է
տպագրության 05.08.2020

Ներածություն

Բնական լեզուների մշակման հետազոտական ուղղությունը վերջին քսան տարում մեծ առաջընթաց է արձանագրել շարահյուսորեն ծանոթագրված կորպուսների շնորհիվ, որոնք անփոխարինելի են լեզվի կամ լեզվի մի առանձին շրջանի վիճակագրական վերլուծության ու մեքենական ուսուցման ալգորիթմների միջոցով լեզվաբանական հետազոտությունների ավտոմատացման համար: Այսպիսի կորպուսներում քերականությունների ձևայնացման ու տվյալների ծանոթագրման համակարգերը շատ հաճախ տարբերվում են միմյանցից հիմնականում տվյալ լեզվի նկարագրության քերականական որոշակի ավանդույթի կամ էլ հետազոտողների շրջանում ընդունված տեսական այս կամ այն մոտեցման պատճառով: Այս հանգամանքը դժվարացնում է տեքստերի գոյություն ունեցող մեքենական մշակման գործիքների կիրառումը նոր լեզուների մեքենական վերլուծության համար և սահմանափակում արդյունքների համադրելիությունը²: Խնդիրը

¹ Սույն հոդվածի թեգերը գեկուցվել են Արցախի Հանրապետության «Գրիգոր Նարեկացի» համալսարանի Արեւմտահայերէնի, հայագիտութեան գիտահետազոտական Լուտովիկա եւ Յակոբ Այնթապլեան կեդրոնի և ՈՒԳԸ կազմակերպած «Հայոց լեզուն անաղարտ պահենք» գիտաժողովում, Մ. Մաշտոցի անվան Մատենադարանի Գանձասարի մասնաճյուղ, 27 մայիսի 2019 թ.:

² Nivre et al. 2007.

հաղթահարելու փորձերն առավելապես ուղղվել են ծանոթագրման միասնական համակարգի միջոցով լեզվաբանական համադրելի տվյալներ ապահովելուն³ կամ այդպիսիք ծանոթագրման անհրաժեշտ համակարգի փոխարկելուն⁴, կամ էլ երկուսը միասին⁵: Լեզվաբանական տվյալների համադրելիության սկզբունքն իր հիմքում ունի «Universal Dependencies (UD) Համընդհանուր կախվածություններ» նախագիծը, որի շրջանակում մշակվել է արդի գրական արևելահայերեն նախադասությունների շարահյուսական կախումների ծառերի բանկ («Հայերենի ծառադարան»), և ձևայնացվել հայերենի քերականությունը:

«Հայերենի ծառադարան» նախագծի մասին

«Հայերենի ծառադարան» նախագիծը⁶ մաս է կազմում Universal Dependencies (UD)–«Համընդհանուր կախվածություններ» հարթակի⁷, որը, տիպաբանական և կիրառական հետազոտական նպատակներով, քերականությունների ձևայնացման և տեքստերի լեզվաբանական ծանոթագրման միասնական մեթոդ է առաջարկում բնական լեզուների մեքենական մշակման համար⁸: UD համակարգը կախվածությունների բացահայտման մեթոդով շարահյուսական ամբողջական կառույցների (որպես կանոն՝ նախադասությունների) վերլուծություն է: UD-ն հիմնվում է բայստորոգյալի գերադասության և նախադասության բայակենտրոն կառուցվածքի մասին պատկերացումների վրա: Նախադասությունների իմաստաշարահյուսական կառուցվածքի վերլուծության ընթացքում որպես «շարահյուսական նվազագույն միավոր» նախադասության մեջ իրար անմիջականորեն ստորադրվում են բառերը՝ իբրև լրացական հարաբերություններ:

³ Zeman et al. 2012.

⁴ McDonald et al. 2013.

⁵ Tsarfaty 2013.

⁶ Նախագիծն իրականացվել է ՀՀ «Գիտության և կրթության հայկական ազգային հիմնադրամի» (ԳԿՀԱՀ, ANSEF) Lingu-4595 և Lingu-5008, ինչպես նաև ISTC Research Grant դրամաշնորհային ծրագրերի շրջանակում, YerevaNN (<https://yerevann.com/>) հետազոտական լաբորատորիայի հետ համագործակցությամբ և ֆ.մ.գ.թ. Հրանտ Խաչատրյանի համադեկավարությամբ: Նախագծի տարբեր փուլերում ծրագրում ընդգրկված են եղել Գոռ Առաքելյանը (ԵՊՀ, YerevaNN), Մարտին Միրաքյանը (ՀԱՀ, YerevaNN): Ծրագրի մասին հանգամանորեն տե՛ս <https://armtreebank.yerevann.com/>: Համացանցային հղումների հասանելիությունը ստուգվել է 02.02.2020 թ.:

⁷ Նախագծի կայքը՝ <https://universaldependencies.org>:

⁸ Nivre et al. 2016.

րով միմյանց կապակցված անջատ միավորներ, և քերականական կախվածություններն արտապատկերվում են շրջված ծառի տեսքով՝ որպես նախադասության շարահյուսական կախումների ծառ:

Նախագիծը 2019 թ. նոյեմբերի դրությամբ ներառում է շարահյուսական ծառերի՝ նույն սկզբունքով ծանոթագրված 157 բանկ⁹ աշխարհի 90 լեզուներով¹⁰:

UD նախագծի շրջանակում 2017 թվականից կառուցվում է արդի գրական արևելահայերեն նախադասությունների շարահյուսական կախումների ծառերի UD_Armenian-ArmTDP բանկը (treebank, ծառադարան), որի 2.5 տարբերակը պարունակում է 2.502 նախադասություն և 52.265 բառանիշ (թողարկվել է 2019 թ. նոյեմբերին): Այս ընթացքում մշակվել է արդի գրական արևելահայերենի ձևային քերականություն¹¹, որը համարվել է նմուշային և ներառվել UD-ի տիպային քերականությունների շարքում:

Հայերենի ծառադարանի տեքստերը վերցված են հայ գեղարվեստական գրականությունից (բացառապես արձակ) և էլեկտրոնային մամուլից (հարցազրույց, մեկնաբանություն, հաղորդագրություն, լուր, բլոգ): Կան նաև իրավական տեքստեր (կառավարության որոշումներ, օրինագծեր, դատական վճիռներ) և դասագրքային օրինակներ: Ամենավաղ թվագրվող նմուշը 1976 թվականից է:

Ծանոթագրումը կատարվում է հետևյալ կերպ. «Հայերենի ծառադարան» կայքում տեքստի մուտքագրումից ու մատենագիտական նկարագրությունից հետո հատույթավորման կամ բառանջատման մեքենական մոդուլի միջոցով տեքստը տրոհվում (tokenization) է պարբերությունների, նախադասությունների և բառանիշերի (token)¹²: Այս փուլից հետո, կրկին մեքենական մոդուլի միջոցով, հիմնվելով նախապես մշակված բառարանների

⁹ Տեսական առումով բանկը դիտարկվում է իբրև լեզվաբանական համապատասխան տեղեկությամբ համալրված տվյալների համախումբ:

¹⁰ UD ծառադարանները հասանելի են <http://hdl.handle.net/11234/1-3105> կայքում:

¹¹ Հայերենի քերականության ձևայնացման սկզբունքները համառոտագրված են <http://universaldependencies.org/hy> կայքէջում: Ամբողջական նկարագրությունները առանձին հղումների տեսքով հասանելի են նույն էջից: Հայերենի քերականության ձևայնացման ընթացքում ուղենշային են եղել հետևյալ աշխատանքները՝ Ջահուկյան 1974, Աբրահամյան և ուրիշներ 1974, Պետրոսյան 1987, Ջահուկյան և ուրիշներ 1980, Իշխանյան 1986:

¹² Բառանջատման մեքենական այս մոդուլը, որը հիմնվում է հայերեն տեքստերի հատույթավորման կանոնների վրա, հասանելի է <https://armtreebank.yerevann.com/tokenization/process/> հասցեով:

վրա, կատարվում է բառանիշերի ձևաբանական վերլուծություն: Բառանիշերից յուրաքանչյուրին վերագրվում է համապատասխան բառույթը (lemmatization)՝ հիմնվելով իմաստային և քերականական հատկանիշների վրա, ապա բառանիշերը խմբավորվում են հատուկ դասերում, այլ կերպ ասած՝ սահմանվում է նրանց խոսքիմասային արժեքը (POS-tagging): Հատուկ պիտակների միջոցով թվարկվում են բառանիշերի իմաստային-քերականական խմբերը և քերականական կարգերը, եթե այդպիսիք առկա են (ձևաբանական պիտակավորում): Ապա ծանոթագրողները ստուգում և անհրաժեշտության դեպքում փոխում են բառանիշերի սահմանները, և եթե նոր բառանիշը չի նույնականացվում բառարանում (այսինքն՝ բառամթերքը նոր է), ապա մեխանիկական եղանակով ավելացվում է համապատասխան բառույթը և ձևաբանորեն պիտակավորվում: Ձևային նկարագրության վերջին փուլում նախադասություն կազմող բառանիշերը գնահատվում են որպես շարահյուսական բառեր, և վեր են հանվում վերջիններիս միջև անմիջական կախումները: Ծանոթագրողները բառանիշերի միջև նշում են շարահյուսական կապերը, և կախումների ծառը պահվում է UD ծառերի բանկերին հարմարեցված CoNLL-U տիպի նիշքում¹³, որն էլ բուն ծառադարանն է:

Ձևաբանական վերլուծություն

UD-ում ձևաբանական նկարագրությունը ձևակազմական կամ ձևույթային ավանդական վերլուծություն չէ, այն ամբողջական բառանիշի համար քերականական հատկանիշների թվարկում է վերջինիս վերագրվող պիտակների տեսքով: Քերականական կարգերն ու հատկանիշներն արտածվում են բառաձևերից (ըստ կազմության) և քերականական կախվածություններից (ըստ գործառության) ու ներկայացվում երեք մակարդակում.

- բառույթի մակարդակ (ներկայացնում է բառիմաստը),
- խոսքիմասային պատկանելության մակարդակ (ներկայացնում է քերականական արժեք ունեցող վերացարկված իմաստը, որը զուգորդվում է տվյալ բառի հետ),

¹³ Նիշքի կառուցվածքի մասին տե՛ս <http://universaldependencies.org/format.html>: Հայերենի ծառադարանի նիշքում ձևից աջ տրվում է նախադասության մեջ բառանիշի նույնական համարը, ապա տրվում են բառանիշը, բառույթը, խոսքի մասը, քերականական հատկանիշները, շարահյուսական կապը, կախումը նախադասության մյուս բառանիշից, հավելյալ նշումներ/տառադարձում:

- քերականական բնութագրերի մակարդակ (ներառում է տվյալ բառին բնորոշ իմաստային-քերականական կամ զուտ քերականական հատկանիշները):

UD նախագծում բառանիշերը խմբավորում են վիճակագրական մոտեցմամբ ընդհանրական՝ *բաց (լիհմաստ)* և *փակ (սպասարկու, թերհմաստ)*, ու մնացորդային սկզբունքով՝ *այլ* դասերում: Առանձնացվում է 17 խոսքի մաս (տե՛ս Աղ. 1), որոնք Google universal part-of-speech tags-ի (UGT)¹⁴ վերանայված տարբերակներն են: Խոսքի մասերի դասակարգման հիմքում իմաստագործառական սկզբունքն է, վիճելի դեպքերում առաջնություն է տրվում գործառական (շարահյուսական) սկզբունքին:

«Հայերենի ծառադարանում» կիրառվում են բոլոր 17 խոսքի մասերը, որոնք պարտադիր են UD նախագծում ներառված ծառադարանների համար: Համեմատությամբ ավանդական հայ քերականությունների՝ առանձին խոսքի մաս է հատուկ անունը (PROPN), տարանջատված են համադասական (CCONJ) և ստորադասական (SCONJ) շաղկապները, դերանվանական որոշիչները (DET) և առարկայանիշ (PRON) դերանունները, առանձնացվում է նաև օժանդակ բայը (AUX): «Հայերենի ծառադարանի» 2.5 տարբերակից սկսած՝ օժանդակ բայեր են գնահատվում նաև *պեղք է* և *պիտի* եղանակիչները: Դերանունները հատկանշային-մակբայական կիրառության դեպքում մակբայներ են: Ածականական դերբայները (հարակատար, ենթակայական, ապառնի II) հիմնականում դիտարկվում են ածական: Ածականներ են բոլոր դասական թվականները (գործառական սկզբունքի հիմքով): Տեքստի մեքենական հատոյթավորման և ծանոթագրման առանձնահատկություններից ելնելով՝ առանձին խոսքի մասեր են տվյալ լեզվի կետադրական նշանները (PUNCT), տվյալ լեզվի համար կետադրական չհամարվող այլ գրանշանները, պատկերանշանները, հղումները, էլ. փոստի հասցեները (SYM), նաև տառային, տառաթվանշային կամ գրանշանային շարքերը, որոնք հնարավոր չէ խմբավորել խոսքիմասային մյուս դասերում (X)¹⁵: Նման մոտեցումը թույլ է տալիս բոլոր բառանիշերի համար ունենալ խոսքիմասային պատկանելության պիտակ:

¹⁴ Slav Petrov et al. 2012.

¹⁵ UD նախագծում հայերենի խոսքի մասերի սահմանման առանձնահատկությունները տե՛ս <http://universaldependencies.org/hy/pos/index.html>:

ԲԱՅ ԴԱՍԻ ՄԻԱՎՈՐՆԵՐ	ՓԱԿ ԴԱՍԻ ՄԻԱՎՈՐՆԵՐ	ԱՅԼ ՄԻԱՎՈՐՆԵՐ
ADJ – Ածական (Adjective)	ADP - Կապ (Adposition)	PUNCT – Կետադրություն (Punctuation)
ADV – Մակբայ (Adverb)	AUX – Օժանդակ բայ (Auxiliary)	SYM – Նիշեր (Symbol)
INTJ – Ձայնարկություն (Interjection)	CCONJ – Համադասական շաղկապ (Coordinating conjunction)	X – Այլ (Other)
NOUN – Գոյական (Noun)	DET – Դերանվանական որոշիչ (Determiner)	
PROPN – Հատուկ անուն (Proper noun)	NUM - Թվական (Numeral)	
VERB – Բայ (Verb)	PART – Վերաբերական (Particle)	
	PRON – Առարկայանիշ դերանուն (Pronoun)	
	SCONJ – Ստորադասական շաղկապ (Subordinating conjunction)	

Աղ. 1. Խոսքի մասերը և դրանց պիտակավորումը UD նախագծում

Համակարգը, բացի խոսքիմասային պիտակավորումից, յուրաքանչ-յուր բառանիշի վերագրում է քերականական բնութագրեր՝ ըստ տվյալ խոսքի մասին բնորոշ քերականական կարգերի (հոլով, դեմք, թիվ, եղանակ և այլն): UD-ում առանձնացվում է 17 համընդհանուր այդպիսի կարգ՝ բայական և անվանական: «Հայերենի ծառադարանում» օգտագործվում է դրանցից 13-ը (չեն օգտագործվել սեռի (Gender), անվան դասի (NounClass), անձներականության (Clusivity) ու բացարձակ ստույգ (հավաստի) գործողության (Evident) քերականական կարգերը)¹⁶: Ի տարբերություն խոսքիմասայինի՝ քերականական հատկանիշների պիտակավորումն ավելի ճկուն է և հնարավոր է ավելացնել տվյալ լեզվին բնորոշ հատկանիշներ՝ ընտրելով պիտակների Interset interlingua for morphosyntactic tagsets ցանկից¹⁷: Հայերենի համար առանձնահատուկ են դիտվել ըստ դեմքի (Person[psor]) և ըստ թվի (Number[psor]) դիմաստացականության քերականական կարգերը: Դիմավոր բայերի հաստատական և ժխտական ձևերի նկարագրության զուգաձևությունը պահպանելու համար ժխտական դերբայը դիտվել է

¹⁶ UD նախագծում հայերենի իմաստային քերականական խմբերի ու քերականական կարգերի ամբողջական ցանկը և նկարագրությունը տե՛ս <http://universaldependencies.org/hy/feat/index.html>:

¹⁷ Daniel Zeman et al. 2008.

որպես ժխտման բույան տիպի հատկանիշ¹⁸ ունեցող պայմանական եղանակի դիմավոր բայածև (Connegative)¹⁹:

ԱՆՎԱՆԱԿԱՆ ՔԵՐԱԿԱՆԱԿԱՆ ԿԱՐԳԵՐ	ԲԱՅԱԿԱՆ ՔԵՐԱԿԱՆԱԿԱՆ ԿԱՐԳԵՐ
Gender – Քերականական սեռ	VerbForm – Դիմավոր և անդեմ ձևեր
Animacy – Անձի և ոչ անձի (իրի) առում	Mood – Եղանակ
NounClass – Անվան դաս	Tense – Ժամանակ
Number – Թվի կարգ	Aspect – Կերպ
Case – Հոլով	Voice – Բայի սեռ
Definite – Առկայացում (որոշյալություն)	Evident – Բացարձակ ստույգ (հավաստի) գործողություն
Degree – Համեմատության աստիճաններ	Polarity – Ժխտում
+Person[psor] – Դիմատացականություն (առկայացում) ըստ դեմքի	+Connegative – Ժխտման բայածև (ժխտ. դերբայ)
	Person – Դեմք
+Number[psor] – Դիմատացականություն (առկայացում) ըստ թվի	Polite – Հարգանքի (հարգական) հոգնակի
	Clusivity – Անձներականություն

Աղ. 2. Քերականական կարգերի պիտակները և անվանումները UD նախագծում

Բացի քերականական կարգերից, հայերենի համար առանձնացվել է 15 իմաստային-քերականական խումբ՝ համընդհանուր 6-ի դիմաց:

ԻՄԱՍՏԱՅԻՆ ՔԵՐԱԿԱՆԱԿԱՆ ԽՄԲԵՐ	
PronType	Դերանունների տեսակներ
+Distance	Ցուցականության շարքեր
NumType	Թվականների տեսակներ
+NumForm	Թվականների տիպեր (արաբական, հռոմեական, հայկական և այլն)
Poss	Ստացականություն (բույան հատկանիշ)
Reflex	Անդրադարձություն (բույան հատկանիշ)
+NameType	Հատուկ անվան տեսակներ (տեղանուն, անձնանուն, մականուն և այլն)
+AdpType	Կապերի տեսակներ (նախադրություններ, հետադրություններ, նախդրավորներ)

¹⁸ Ֆունկցիա բույան հանրահաշվում և մաթեմատիկական տրամաբանության մեջ: UD-ում այն օգտագործվում է չհակադրվող հատկանիշները պիտակավորելու համար:

¹⁹ Դիմավոր և անդեմ բայերը UD համակարգում, զուտ փորձարարական օրինաչափություններից ելնելով, տարբերակվում են առավելապես եղանակի քերականական կարգի հատկանիշով:

+ConjType	Շաղկապների տեսակներ (զուգադրական կիրառություններ)
Abbr	Հապավում, համառոտագրություն (բուլյան հատկանիշ)
+Hyph	Հատվածական բաղադրությունների առաջին, անավարտ (զծիկավոր) բաղադրիչ
Foreign	Օտարալեզու (օտարագիր) բառեր, ոչ փոխառություններ (բուլյան հատկանիշ)
+Style	Ոճեր (ժողովրդական, խոսակցական, հնացած և այլն)
+Echo	Կրկնավոր հարադրությունների փոփոխված բաղադրիչ
+Typo	Տառախախտումով բառանիշեր (բուլյան հատկանիշ)

Աղ. 3. Իմաստային քերականական խմբերի պիտակները և անվանումները UD նախագծում

Շարահյուսական կախումների բացահայտում

Շարահյուսական ծանոթագրումը UD-ում հիմնված է կախվածությունների բացահայտման Ստենֆորդի մոդելի վրա²⁰ և ունի քերականական կախվածության 37 հարաբերություն: Մոդելը շեշտադրում է նյութական իմաստ արտահայտող (լիմաստ) բառերի միջև կախումների բացահայտումը, սպասարկու բառերը դիտվում են անմիջապես կախված վերջիններից և մշտապես եզրային (ծայրային) հանգույցներ են, որոնց վրա ընդհատվում են կախվածության շղթաները: Մոտեցման նպատակը կրկին նկարագրության համադրելիությունը պահպանելն է. նյութական իմաստ արտահայտող բառերի կապակցելիությունը զուգաձև է տարբեր լեզուներում, մինչդեռ սպասարկու բառերով արտահայտվող լրացական հարաբերությունները կարող են արտահայտվել վերջավորություններով կամ գրոյական ձևերով:

Հայերեն նախադասությունների շարահյուսական կախումների ծանոթը կազմելու համար օգտագործվել է հայերենին բնորոշ 15 կախվածության հարաբերություն, բացի համընդհանուր կիրառելի 36-ից (չի օգտագործվել ընդամենը 1 հարաբերություն, *clf*)²¹: Հայերենի համար ընդունվել են բառերի միջև կախումների հետևյալ կանոնները. ենթական կախյալ է ստորոգյալից (*nsbj*), կապերը կախված են խնդրառվող գոյականից (*case*, *case:loc*), ածականի իմաստը ճշգրտող մակբայը կախված է ածականից (*advmod*), ածականի կամ մակբայի իմաստը մասնավորեցնող գոյականները

²⁰ de Marneffe et al. 2006, de Marneffe et al. 2008, de Marneffe et al. 2014.

²¹ «Հայերենի ծառադարանում» կիրառված շարահյուսական կապերի ամբողջական ցանկը տե՛ս <http://universaldependencies.org/hy/dep/index.html>:

(վարքով հայտնի) կախված են դրանցից (obl), գոյականի իմաստը ճշգրտող խոսքի մասերը՝ գոյականից (nmod, amod, advmod:emph): Կախումները դրսևորվում են խնդրառությամբ, համաձայնությամբ և առդրությամբ:

Հայերենի ծառադարանում ուղիղ և հանգման խնդիրները (որպես ուղղական/հայցական և սեռական/տրական հոլովներով բայական լրացումներ) վերլուծվում են որպես անցողական և անանցողական բայերի *անմիջական, բուն լրացումներ* (core arguments), ընդ որում, բայի հետ վերջիններիս շարահյուսական կապը՝ կախումը ստորոգյալից, նշվում է որպես obj (խնդիր), իսկ հանգման խնդրի դեպքում մասնավորեցվում որպես անուղղակի խնդիր (iobj) միայն այն դեպքում, երբ միաժամանակ առկա են բայի և՛ ուղիղ, և՛ անուղղակի խնդիր լրացումներ: Մյուս հոլովներով և կապերով արտահայտված խնդիրներն ու պարագաները վերլուծվում են որպես «խոսորդ» խնդիրներ և պարագաներ (obl - oblique arguments and adjuncts):

Բայերի՝ միայն մակբայներով արտահայտված պարագայական լրացումները նկարագրվում են advmod, իսկ պարագայական երկրորդական նախադասությունները՝ advcl լրացական հարաբերությամբ: Բայի բուն լրացում է համարվում նաև ենթական (nsubj), որը կարող է արտահայտվել նախադասությամբ (csubj): Բայական լրացումների շարահյուսական դիրքում իրացված երկրորդական նախադասությունների կախվածությունը բացահայտվում է ccomp և xcomp շարահյուսական կապերի միջոցով²²:

Շարահյուսական ccomp (clausal complement) կապը կիրառվում է ուղիղ խնդիր երկրորդական նախադասությունները վերլուծելիս: Այս կապով է բացահայտվում նաև հայերենի «դիմավոր բայ+անորոշ դերբայի ուղիղ ձև» կապակցությամբ արտահայտված բարդ ստորոգյալների անորոշ դերբայը, եթե վերջինիս գործողն անհայտ է: Բարդ ստորոգյալների անորոշ դերբայները բուն բային ստորադրվում են նաև xcomp (open clausal complement) կապի միջոցով, երբ դրանց գործողը/ենթական հայտնի կամ վերականգնելի է նախադասության իմաստից: xcomp կապը կիրառվում է չեզոք, նաև վերադրառու (վերացական) բայերի միջոցով ենթակային վերագրվող հատկանիշը ծանոթագրելիս, այլ կերպ ասած՝ անվանաբայական ստորոգյալները վերլուծելիս (*թվալ գեղեցիկ, երևալ խելացի, համարել*

²² «Հայերենի ծառադարանում» ccomp և xcomp շարահյուսական կապերի նկարագրությունը տե՛ս <https://universaldependencies.org/hy/dep/ccomp.html> և <https://universaldependencies.org/hy/dep/xcomp.html>:

դավաճան) ընդունվում է, որ առկա է կրկնակի ստորոգում՝ տրամաբանական ենթականերով:

Կապակցող սպասարկու բառերը, որոնք հայ քերականությունները նախադասության ինքնուրույն անդամ չեն համարում, UD-ում նախադասության կառուցվածքի անմիջական տարրեր են ձայնարկությունների, ներդրյալ միավորների (parataxis, discourse) հետ մեկտեղ: Շարահյուսորեն վերլուծելի են նաև օժանդակ բառերը (օժանդակ բայ, եղանակիչ, ժխտական բառ-մասնիկ, թարմատար), որոնք հայ քերականություններում բառաձևի առանձին գրվող բաղադրիչներ են:

Կայուն բառակապակցությունները (հարադրություններ, բաղադրյալ անվանումներ, դարձվածքներ) դիտարկվում են «բազմաբառ արտահայտություններ» (multiword expressions), որոնցում կախյալները, որպես եզրային հանգույց, ծանոթագրվում են կախվածության, ըստ էության, բառակազմական արժեք ունեցող հարաբերություններով (compound, flat, fixed, goeswith):

Եզրակացություններ

«Հայերենի ծառադարանը» կիրառելի է ինչպես հայերեն տեքստերի մեքենական վերլուծության գործիքներ, վիճակագրական մոդելներ մշակելու, այնպես էլ տեքստի մեքենական մշակման համակարգերի թեստավորման ու գնահատման համար: Առաջին հնարավորությունն օգտագործվել է տվյալահենք (data-driven) կիսահիմքնուրույն ուսուցման (semi-supervised learning) COMBO նեյրոնային ցանցի²³ հենքով հայերեն տեքստի մեքենական վերլուծության առցանց համակարգ ստեղծելու համար²⁴:

«Հայերենի ծառադարան» նախագծում աշխատանքները շարունակվելու են երեք ուղղությամբ. ընդլայնվելու է արևելահայերենի ծառադարանը մինչև նվազագույնը 100 հազար բառանիշ, հղկվելու է արևելահայերենի ձևայնացված քերականությունը՝ որպես ոլորտային հետազոտություններում կիրառելի ստանդարտ: Նույն ճանապարհը կրկնվելու է արևմտահայերենի համար:

²³ Piotr Rybak et al. 2018.

²⁴ Մանրամասները տե՛ս <https://github.com/Armtreebank/End-to-end-Parser>, գործիքի առցանց փորձնական տարբերակը հասանելի է <https://parser.yerevann.com/> կայքում: Նախագծի շրջանակում նմանատիպ մեկ այլ լուծման մասին հանգամանալից՝ Arakelyan et al. 2018.

Գրականություն

- Աբրահամյան Ս.Գ., Պառնասյան Ն.Ա., Օհանյան Հ.Ա. 1974, Ժամանակակից հայոց լեզու, հ. 2, Ձևաբանություն, Երևան, ՀՍՍՀ ԳԱ հրատ., 587 էջ:
- Իշխանյան Ռ. 1986, Արդի հայերենի շարահյուսություն: Պարզ նախադասություն, Երևան, Երևանի համալսարանի հրատ., 340 էջ:
- Պետրոսյան Հ.Զ. 1987, Հայերենագիտական բառարան, Երևան, «Հայաստան», 686 էջ:
- Ջահուկյան Գ. Բ. 1974, Ժամանակակից հայերենի տեսության հիմունքները, Երևան, ՀՍՍՀ ԳԱ հրատ., 586 էջ:
- Ջահուկյան Գ. Բ., Աղայան Է.Բ., Առաքելյան Վ.Դ., Քոսյան Վ.Ա. 1980, Հայոց լեզու: Ներածություն, հնչյունաբանություն, բառագիտություն, դարձվածաբանություն, 1-ին մաս, Ա պրակ, Երևան, «Լույս», 528 էջ:
- Zeman D., Resnik Ph. 2008, Cross-Language Parser Adaptation between Related Languages. In Proceedings of the IJCNLP-08 Workshop on NLP for Less Privileged Languages, p. 35-42.
- Zeman D., Mareček D., Popel M., Ramasamy L., Štěpanek J., Žabokrtský Z., Hajič J. 2012, HamleDT: To Parse or not to Parse? In: Proceedings of the 8th International Conference on Language Resources and Evaluation (LREC), p. 2735-2741.
- Arakelyan G., Hambardzumyan K., Khachatryan H. 2018, Towards JointUD: Part-of-speech Tagging and Lemmatization using Recurrent Neural Networks. In: Proceedings of the CoNLL 2018 Shared Task: Multilingual Parsing from Raw Text to Universal Dependencies, p. 180-186.
- Nivre J., Megyesi B. 2007, Bootstrapping a Swedish Treebank Using Cross-Corpus Harmonization and Annotation Projection, In: Proceedings of the 6th Workshop on Treebanks and Linguistic Theories (TLT), p. 97-102.
- Nivre J., de Marneffe M.-C., Ginter F., Goldberg Y., Hajič J., Manning C.D., McDonald R., Petrov C., Pyysalo C., Silveira C., Tsarfaty H., Zeman D. 2016, Universal Dependencies v1: A Multilingual Treebank Collection, In: Proceedings of the Tenth International Conference on Language Resources and Evaluation (LREC'16), p. 1659-1666.
- de Marneffe M.-C., MacCartney B., Manning C.D. 2006, Generating Typed Dependency Parses from Phrase Structure Parses, In: *Proceedings of the Fifth International Conference on Language Resources and Evaluation (LREC'06)*, p. 449-454.

- de Marneffe M.-C., MacCartney B., Manning C.D. 2008, The Stanford Typed Dependencies Representation. In: Proceedings of the Workshop on Cross-Framework and Cross-Domain Parser Evaluation, p. 1-8.
- de Marneffe M.-C., Dozat D., Silveira N., Haverinen K., Ginter Ph., Nivre J., Manning C.D. 2014, Universal Stanford Dependencies: A Cross-Linguistic Typology, In: Proceedings of the Ninth International Conference on Language Resources and Evaluation (LREC'14), p. 4585-4592.
- Rybak P., Wroblewska A. 2018, Semi-Supervised Neural System for Tagging, Parsing and Lemmatization, In: Proceedings of the CoNLL 2018 Shared Task: Multilingual Parsing from Raw Text to Universal Dependencies, p. 45-54.
- Tsarfaty R. 2013, A Unified Morpho-Syntactic Scheme of Stanford Dependencies, In: Proceedings of the 51st Annual Meeting of the Association for Computational Linguistics, vol. 2: Short Papers, p. 578-584.
- McDonald R., Nivre J., Quirnbach-Brundage Y., Goldberg Y., Das D., Ganchev K., Hall K., Petrov S., Zhang H., Täckström O., Bedini Cl., Castello N.B., Lee J. 2013, Universal Dependency Annotation for Multilingual Parsing, In: Proceedings of the 51st Annual Meeting of the Association for Computational Linguistics, vol. 2: Short Papers, p. 92-97.
- Petrov S., Das D., McDonald R. 2012, A Universal POS Tagset, In: Proceedings of the Eighth International Conference on Language Resources and Evaluation (LREC'12), p. 2089-2096.

ՀԱՄԸՆԴՀԱՆՈՒՐ ԿԱԽՎԱԾՈՒԹՅՈՒՆՆԵՐ ԵՎ ՀԱՅԵՐԵՆԻ ԾԱՌԱԴԱՐԱՆԸ

Մարատ Յավրումյան, Աննա Դանիելյան

Ամփոփում

Վերջին տարիներին զգալիորեն աճել է հետաքրքրությունը ծանոթագրման համակարգերի նկատմամբ, որոնք կարող են օգտագործվել բազմաթիվ լեզուներում: Հիմնվելով ձևաբանական և շարահյուսական ծանոթագրման միասնականացման վրա՝ «Universal Dependencies (UD) -Համընդհանուր կախվածություններ» նախագիծը նպատակ ունի ստեղծել տարբեր լեզուների համար կիրառելի խոսքիմասային պիտակների, ձևաբանական հատկանիշների

և կախվածության հարաբերությունների հավաքածու, ինչպես նաև շարահյուսական ծառերի նույն կերպ ծանոթագրված մեծ քանակությամբ բանկեր (ծառադարան):

Արդի գրական արևելահայերենի ծառադարանի (UD_Armenian-Arm TDP) օրինակով ներկայացված են ծանոթագրման UD կաղապարները՝ ծանոթագրման առանձնահատկությունների նկարագրությամբ: Արդյունքները հասանելի են <http://armtreebank.yerevann.com/> հղումով:

Բանալի բառեր – բնական լեզվի մշակում, «Համընդհանուր կախվածություններ (UD)», արևելահայերենի ծառադարան, ծանոթագրման UD կաղապարներ, կախվածության հարաբերություններ, ձևաբանական հատկանիշներ, բառանջատում:

УНИВЕРСАЛЬНЫЕ ЗАВИСИМОСТИ И ТРИБАНК АРМЯНСКОГО ЯЗЫКА

Марат Яврумян, Анна Даниелян

Резюме

В последнее время наблюдается значительный интерес к схемам аннотаций, которые могут быть использованы во многих языках. Проект «Универсальные зависимости» (Universal Dependencies, UD) ставит целью представить кросс-лингвистически применимый набор тегов частей речи, морфологических признаков и отношений зависимостей, а также огромный массив единообразно размеченных банков синтаксических деревьев. На примере банка синтаксических деревьев восточноармянского языка (UD_Armenian-ArmTDP) детализирована схема аннотации по стандарту UD с описанием особенностей аннотации. Результаты доступны на сайте <https://armtreebank.yerevann.com/>.

Ключевые слова – обработка естественного языка, «Универсальные зависимости (UD)», синтаксически аннотированный корпус восточноармянского языка, схемы аннотаций UD, отношения зависимостей, морфологические признаки, токенизация.

UNIVERSAL DEPENDENCIES AND THE ARMENIAN TREEBANK

Marat Yavrumyan, Anna Danielyan

Abstract

There has been a recent significant interest in annotation schemes which can consistently be applied to various languages. Considering the current efforts made in order to unify morphological and syntactic annotations, the Universal Dependencies (UD) project attempts to present quantities of uniformly annotated treebanks, a cross-linguistically applicable part-of-speech tag-set, a feature inventory and a set of dependency relations. We present UD treebank for Eastern Armenian (UD_Armenian-ArmTDP) and details of annotations, according to the Universal Dependencies standard, with discussion of certain challenges. The results are available in at <https://armtreebank.yerevann.com/>.

Key words – natural language processing, «Universal Dependencies», Eastern Armenian Treebank, UD annotation schemes, dependency relations, morphological features, tokenization.