

**ՏԵՔՍՏԻ ՄԵՔԵՆԱԿԱՆ ՀԱՏՈՒՅԹԱՎՈՐՈՒՄԸ
ԱՐԵՎԵԼԱՀԱՅԵՐԵՆԻ ՇԱՐԱՀԱՅՈՒՍԱԿԱՆ ԾԱՌԵՐԻ
UD_ARMENIAN-ArmTDP ԲԱՆԿՈՒՄ**

ՄԱՐԱՏ ՅԱՎՐՈՒՄՅԱՆ

Բնական լեզվով տեքստերի մեքենական վերլուծության համակարգերը ենթադրում են, որ տեքստն ի սկզբանե մասնատված է նախադասությունների, բառերի, կետադրական նշանների, թվանշանների, տառաթվանշանային արտահայտությունների և այլն, այսինքն՝ այն արդեն իսկ հատույթավորված է: Հատույթավորումը, այսպիսով, տեքստի մշակման առաջին, նախնական փուլն է, իսկ վերլուծության հաջորդ՝ ձևաբանական և շարահյուսական մակարդակներում նախընտրվող լուծումները կախված են տեքստի կառուցվածքային այս (նվազագույն) միավորների առանձնացման սկզբունքներից: «Հայերենի ծառադարան» նախագծի շրջանակում¹ մշակվել է հայերեն տեքստերի հատույթավորման կանոնների վրա հիմնված (rule driven) «ՀայՆիշ» մոդուլը, որի միջոցով նախ ինքնաշխատ կերպով հատույթավորվել է 36 հազար բառանիշ (token), ապա հատույթավորման արդյունքները ստուգվել են մեխանիկական եղանակով: Մշակումները կիրառվել են ավելի ընդգրկուն՝ կիսահիմնություն ուսուցման նեյրոնային ցանցի հենքով հայերեն տեքստերի մեքենական վերլուծության մոդուլ կառուցելու խնդրի շրջանակում:

ՄՈՒՏՔ

Հատույթավորումը լեզվաբանական վերլուծության եղանակ է, խոսքաշարի (տեքստի) գծային մասնատում կամ տրոհում (անդամատում) լեզվական միավորների: Հատույթավորման նպատակը հնչյունաբանական, ձևաբանական կամ շարահյուսական միավորների բացահայտումն է՝ պայմանավորված նրանով, թե կառուցվածքային որ մակարդակում է վերլուծությունը կատարվում²:

¹ Նախագիծը (<https://armtreebank.yerevann.com/>) իրականացվել է «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 համադրվածությամբ: Նախագծի տարբեր փուլերում ընդգրկված են եղել Աննա Դանիելյանը (ԵՊՀ), Գոռ Առաքելյանը (ԵՊՀ, YerevaNN), Մարտին Միրաքյանը (ՀԱՀ, YerevaNN):

Համացանցային բոլոր հղումների հասանելիությունը ստուգվել է 15.09.2019թ.:

² Տե՛ս **Հ. Պետրոսյան**, Հայերենագիտական բառարան, Եր., 1987, էջ 366-367:

Բնական լեզվով տեքստերի մեքենական մշակման համակարգերում տեքստի (գրավոր խոսքի) հատույթավորումը կատարվում է գրանշանային (գրույթային) վերլուծության միջոցով և հիմնվում է տվյալ լեզվի ուղղագրության կանոնների վրա: Ենթադրվում է, որ կանոնների մանրամասնումը կարող է ապահովել կետադրված տեքստերի հնարավոր բոլոր իրական դեպքերի ճշգրիտ հատույթավորումը³:

Գրանշանային ամենապարզ վերլուծությունը տեքստի տրոհումն է գրանշանների ընդհատական շարքերի՝ որոշ ընդհատումների վերագրելով լեզվական արժեք⁴: Վերջիններս գրավոր խոսքում կա՛մ նշանակվում են բացատրով, կա՛մ հատուկ՝ կետադրական նշաններով և ցույց են տալիս ընդհատման տարբեր աստիճաններ: Տեքստի անդամատման կառուցվածքային այս մակարդակում բացահայտվող նվազագույն միավորները (հատույթները), որոնք խմբավորվում են վերջավոր դասերում, մեքենական համակարգերում անվանվում են բառանիշեր (token):

Տեքստում կառուցվածքային նվազագույն միավորների տարանջատման կամ տեքստի բառանիշավորման (tokenization) համար էական է համատեքստը, որում ներառված է տվյալ բառանիշը. հենց համատեքստն է թույլ տալիս հստակեցնել, թե իրականում գրանշանային քանի հատույթի կամ բառանիշի հետ գործ ունենք (հմմտ. հարադրավոր բարդություններ, անջատ կամ գծիկով գրվող բառեր և այլն): Որպես այդպիսի համատեքստեր մեքենական համակարգերում հանդես են գալիս նախադասությունները՝ առաջադրելով տեքստում նախադասությունների անդամատման կամ նախադասությունների սահմանազատման խնդիրը:

Արդի գրական արևելահայերեն տեքստերի մեքենական հատույթավորումը հաշվողական (համակարգչային) լեզվաբանության բնագավառում որպես ինքնուրույն հետազոտական խնդիր չի դիտարկվել, թեև ինքնին հասկանալի է, որ նախագծերում, որոնք առնչվում են հայերենի քերականության ձևայնացմանը, այն անուղղակիորեն քննարկվել և որոշակի հաջողությամբ լուծվել է (ընդունված որոշումների արդյունավետությունն առանձին քննարկման առարկա է)⁵:

³ Նման մոտեցում է կիրառվել, օրինակ, տեքստի մեքենական վերլուծության <http://aot.ru/> համակարգում, որի մի շարք լուծումներ ընդունվել են «ՀայՆիշ» մոդուլը մշակելիս:

⁴ Տե՛ս **Գ. Ջահուկյան**, Ժամանակակից հայերենի տեսության հիմունքները, Եր., 1974, էջ 97-98:

⁵ Հմմտ. բառամթերքի տրոհումը «Արևելահայերենի ազգային կորպուսում» (ԱԼԵՎԱԿ, <http://eanc.net>), կամ՝ **Լ. Հովսեփյան**, Հայերենի քերականության ձևայնացում և համընդհանուր ցանցային լեզվի հայերեն մոդուլի մշակում // Արևելագիտության հարցեր, Եր., 2006, հ. 6, էջ 144-156, **Ռ. Ուռուտյան**, **Պ. Ղազանչյան**, **Ե. Ստեփանյան**, **Գ. Սուֆյան**, Հաշվողական տեխնիկայի կիրառումը տեքստի որոշակիացման հարցում // Լեզվի և ոճի հարցեր, 1988, № 11, էջ 136-151, **Է. Եղիազարյան**, Մեքենական բառարանների կառուցման որոշ հարցեր // Լեզվի և ոճի հարցեր, 1982, № 6, էջ 186-198, **Ռ. Ուռուտյան**, Ժամանակակից հայերենի անվանական բառափոփոխման ձևային նկարագրությունը // Լեզվի և ոճի հարցեր, 1982, № 6, էջ 134-185, **Ս. Մանուկյան**, Բառի տրոհումը ավտոմատ ձևաբանական վերլուծության համար // Բառ, նախադասություն, տեքստ, Եր., 1987, էջ 34-40, **Ս. Միմոնյան**, Նախադասության շարահյուսական կա-

Հոդվածում քննարկվում և տրվում են արդի գրական արևելահայերեն տեքստերի հատույթավորման, այս դեպքում՝ նախադասությունների սահմանագատման և բառանիշավորման (բառանջատման) կանոնները, որոնք կիրառվել են «Հայերենի ծառադարան» նախագծում և դրվել «ՀայՆիշ» մեքենական մոդուլի հիմքում:

«ՀԱՅԵՐԵՆԻ ԾԱՌԱԴԱՐԱՆ» ՆԱԽԱԳԾԻ ՄԱՍԻՆ

«Հայերենի ծառադարան» նախագծի նպատակը արդի գրական արևելահայերեն նախադասությունների շարահյուսական կախումների ծառերի նմուշային բանկի կամ ծառադարանի (treebank) ստեղծումն է: Նախագիծը միտված է նաև արևելահայերեն տեքստերի գրանշանային, ձևաբանական (նաև բառակազմական) և իմաստային-շարահյուսական առանձին, ինքնաշխատ վերլուծիչներ (parser) ստեղծելու գաղափարի իրականացմանը:

«Հայերենի ծառադարան» նախագիծը մաս է կազմում Universal Dependencies (UD) – «Համընդհանուր կախվածություններ» հարթակի, որը տիպաբանական և կիրառական հետազոտական նպատակներով քերականությունների ձևայնացման և տեքստերի լեզվաբանական ծանոթագրման միասնական մեթոդ է առաջարկում բնական լեզուների մեքենական մշակման համար⁶: UD համակարգը կախվածությունների բացահայտման մեթոդով շարահյուսական ամբողջական կառույցների (որպես կանոն՝ նախադասությունների) վերլուծություն է: UD-ն հիմնվում է բայ-ստորոգյալի գերադասության և նախադասության բայակենտրոն կառուցվածքի մասին պատկերացումների վրա: Նախադասությունների իմաստաշարահյուսական կառուցվածքի վերլուծության ընթացքում իրար անմիջականորեն ստորադրվում են բառերը՝ իբրև լրացական հարաբերություններով միմյանց կապակցված անջատ միավորներ, և քերականական կախվածություններն արտապատկերվում են շրջված ծառի տեսքով՝ որպես նախադասության շարահյուսական կախումների ծառ: UD նախագիծը 2019 թ. մայիսի դրությամբ ներառում է շարահյուսական ծառերի նույն սկզբունքով ծանոթագրված 146 բանկ⁷ աշխարհի 83 լեզուներով⁸:

UD նախագծի շրջանակում 2017-ից կառուցվում է արդի գրական արևելահայերեն նախադասությունների շարահյուսական կախումների ծառերի UD_Armenian-ArmTDP բանկը, որի 2.4 տարբերակը պարու-

խումների ծառերի վերլուծության և փոխակերպման համակարգ // Բառ, նախադասություն, տեքստ, Եր., 1987, էջ 99-102 և այլ աշխատանքներ:

⁶ Տե՛ս **Joakim Nivre, Marie-Catherine de Marneffe, Filip Ginter, Yoav Goldberg, Jan Hajič, Christopher D. Manning, Rvan McDonald, Slav Petrov, Sampo Pyysalo, Natalia Silveira, Reut Tsarfaty, Daniel Zeman.** 2016. Universal Dependencies v1: A Multilingual Treebank Collection. In *Proceedings of LREC*: Նախագծի կայքը՝ <https://universaldependencies.org>:

⁷ Տեսական առումով բանկը դիտարկվում է իբրև լեզվաբանական համապատասխան տեղեկությամբ համալրված տվյալների համախումբ:

⁸ UD ծառադարանները հասանելի են <http://hdl.handle.net/11234/1-2988> կայքում:

նակում է 1742 նախադասություն և 36.368 բառանիշ (թողարկվել է 2019 թ. մայիսին): Այս ընթացքում մշակվել է հայերենի ձևային քերականություն⁹, 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 նմուշը 1976 թվականից է:

Ծանոթագրումը կատարվում է հետևյալ կերպ. «Հայերենի ծառադարան» կայքում տեքստի մուտքագրումից ու մատենագիտական նկարագրությունից հետո հատույթավորման մեքենական մոդուլի միջոցով տեքստը տրոհվում է պարբերությունների, նախադասությունների և բառանիշերի¹⁰: Այս փուլից հետո, հիմնվելով նախապես մշակված բառարանների վրա, կրկին մեքենական մոդուլի միջոցով 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): Այնուհետև ծանոթագրողները ոչ մեքենական եղանակով ստուգում և անհրաժեշտության դեպքում փոխում են բառանիշերի սահմանները, և եթե նոր բառանիշը չի նույնականացվում բառարանում (այսինքն՝ բառամթերքը նոր է), ապա ձեռքով 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 ձեռքով նշում են շարահյուսական կապերը, և կախումների ծառը պահվում է UD ծառերի բանկերին հարմարեցված CoNLL-U տիպի նիշքում¹¹, որն էլ բուն ծառադարանն է:

⁹ Հայերենի քերականության ձևայնացման սկզբունքները համառոտագրված են <http://universaldependencies.org/hy> կայքէջում: Ամբողջական նկարագրությունները առանձին հղումների տեսքով հասանելի են նույն էջից: Աշխատանքները կատարվել են ԵՊՀ արաբագիտության ամբիոնի աշխատակից Աննա Դանիելյանի համահեղինակությամբ:

¹⁰ Տեքստի հատույթավորման մեքենական այս մոդուլը առցանց հասանելի է <https://armtreebank.yerevan.com/tokenization/process/> հասցեով, նախագծվել և իրականացվել է YerevaNN հետազոտական լաբորատորիայում Գոռ Առաքելյանի կողմից:

¹¹ Նիշքի կառուցվածքի մասին տե՛ս <http://universaldependencies.org/format.html>:

«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) կիսահստատեսային ուսուցման (semi-supervised learning) COMBO ներդրումային ցանցի¹² հենքով հայերեն տեքստի մեքենական վերլուծության առցանց մոդուլ ստեղծելու համար¹³:

ՏԵՔՍՏԻ ՀԱՏՈՒԹՅԱՎՈՐՄԱՆ ՄԿՋԲՈՒՆՔՆԵՐԸ

Չնայած թվացյալ պարզությանը՝ տեքստի հատույթավորման խնդիրը միանշանակ չէ շատ լեզուներում: Խորհրդանշական է, որ տեքստի «բառակենտրոն» վերլուծության կամ բառի սահմանների շուրջ 1950-60-ականների լեզվաբանական բանավեճը ևս հանգեց բառի գուտ ձևային սահմանման՝ որպես գրավոր խոսքաշարում բացատրված առանձնացված տեքստային միավորի, բառաձևի¹⁴:

Տեքստի մեքենական մշակման համակարգերում նույնպես կիրառվում է այս մոտեցումը՝ թե որքանով է կիրառելի բացատր գրանշանների ընդհատական շարքերում լեզվական արժեք ունեցող ընդհատումներ նշելու համար: Այս մոտեցմամբ տեքստի հատույթավորման «ՀայՆիշ» մոդուլի համար մուտքային են գրանշանների գծային շարքերը (հայերեն և այլ այբուբեններով տառեր, կետադրական նշաններ, թվանշաններ, բացատներ, այլ գրանշաններ): Ելքում այս շարքերը տրոհվում են, այլ կերպ՝ հատույթավորվում են բառանիշերի, նախադասությունների և պարբերությունների: Ընդ որում, նախադասությունը կազմված է բառանիշերից, իսկ պարբերությունը՝ նախադասություններից: Առանձնահատուկ պետք է նշել, որ տեքստի կառուցվածքային վերլուծության այս փուլը լեզվաբանական ոչ մի հավելյալ տեղեկատվություն չի պարունակում (օր. տարբեր տեսակի ցանկեր՝ անջատ կամ գծիկով գրվող բառերի, համառոտագրությունների և այլն, որոնցում թվարկվում են այս կամ այն կանոնից բացառությունները):

Կարևոր է, որ վերլուծության հաջորդ մակարդակներում բառանիշերի հետագա տրոհման անհրաժեշտություն չառաջանա, այլ կերպ ասած՝ որոշումը, թե ինչպիսի միավորներ են հետագայում ենթարկվելու

«Հայերենի ծառադարանի» նիշքում ձևից աջ տրվում են նախադասության մեջ բառանիշի նույնական համարը, ապա բառանիշը, բառույթը, խոսքի մասը, քերականական հատկանիշները, շարահյուսական կապը, կախումը նախադասության մյուս բառանիշից, հավելյալ նշումներ/տառադարձում:

¹² Տե՛ս **Piotr Rybak and Alina Wroblewska**. 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*, էջ 45-54, Brussels, Belgium, October 31 – November 1, ACL, 2018:

¹³ Մանրամասները տե՛ս <https://github.com/Armtreebank/End-to-end-Parser>, գործիքի առցանց փորձնական տարբերակը հասանելի է <https://parser.yerevann.com/> կայքում:

¹⁴ Հմմտ. **Кузнецов П. С.** Опыт формального определения слова // Вопросы языкознания, 1964, № 5, էջ 75-77:

ձևաբանական կամ շարահյուսական վերլուծության, կայացվի այս փուլում: Վիճելի կամ ոչ միանշանակ դեպքերի (օրինակ՝ անջատ և գծիկով գրվող բառեր, բառամիջյան կետադրական նշաններ, համառոտագրություններ, բացատ կամ գծիկ պարունակող թվանշաններ և այլն) նկարագրությունն իրականում պայմանավորված է նախագծի նպատակներով: Կարևոր է, սակայն, այս հարցում նկարագրության միօրինակության սկզբունքի պահպանումը:

Նկարագրության այս փուլում հիմնական տարբերակումը փաստորեն բառանիշի և (շարահյուսական) բառի միջև է, որի արդյունքում առաջանում է «բազմաբառ բառանիշերի» (multiword tokens) մասին պատկերացումը, երբ մեկ բառանիշը համապատասխանում է մի քանի (շարահյուսական) բառերի (հմմտ. գերմաներեն՝ zum=zu+dem նախադրությունը կամ շատ ավելի պարզ՝ բացատով առանձնացված 20 000 թվանշանը): Երբեմն անհրաժեշտ է լինում անել հակառակը և մի քանի բառանիշ միավորել մեկ շարահյուսական բառում (հմմտ.՝ հարադրավոր բարդությունները): Այսպիսի դեպքերի նկարագրության համար ներմուծվում է «բազմաբառ արտահայտությունների» (MWE, multiword expressions) մասին պատկերացումը: Վերջիններս՝ որպես անջատ բառանիշեր, շարահյուսական մակարդակում ծանոթագրվում են կախվածության հատուկ ըստ էության բառակազմական արժեք ունեցող և իմաստային սերտաճման տարբեր աստիճաններն արտացոլող կապերի միջոցով (goeswith, fixed, flat, compound, conj):

ՏԵՔՍՏԻ ԲԱՌԱՆԻՇԱՎՈՐՈՒՄ, ԲԱՌԱՆՁՍՈՒՄ

«Հայերենի ծառադարան» նախագծում արդի գրական արևելահայերեն տեքստերի հատույթավորման կանոնները մշակելիս և դրանք «ՀայՆիշ» մեքենական մոդուլում կիրառելիս էլքային են համարվել հետևյալ դրույթները.

ա) բառանիշերը բացատ չեն կարող պարունակել,

բ) բացատը բառանիշ չի կարող համարվել,

գ) գրանշանների միանման շարքերը տրոհվում են նույն կերպ, բոլոր ոչ բացատային նիշերը, որոնք առկա են մուտքային տեքստում, պահպանվում են նաև էլքում:

Ընդ որում, հստակ տարանջատվում են գրանշանների հայատառ և ոչ հայատառ շարքերը, ինչը նշանակում է, որ որոշակի տարբերություններ կան նաև դրանց բառանիշավորման կանոնների միջև: Հայերենի գրանշանների հավաքածուն ունի հետևյալ տեքստը.

: . , « » () ... — - ' - ~
0123456789ԱաԲբԳգԴդԵեԶզԷէԸըԹթԺժԻիԼլԽխԾծԿկՀհՁզՂղՃճՄմՅյՆն
ՇշՈոՉչՊպՋՋՌՌՍսՎվՏտՐրՑցԻփՔքԼլՕօՖֆ

Հիմնվելով այս սկզբունքների վրա՝ սահմանվել են բառանիշավորման հետևյալ կանոնները.

1. Բացատները միշտ տրոհում են բառանիշեր. սա ենթադրում է,

որ չեն կարող լինել բացասներ պարունակող բառանիշեր:

2. Կետադրությունը ենթակա է բառանիշավորման:

2.1. Համառոտագրություններում կրճատման նշան հանդիսացող կետը չի համարվում բառանիշի մաս և մասնատվում է որպես անջատ բառանիշ, օր.՝ *Ֆր.* տրոհվում է որպես { ֆր } և { . }:

2.2. «Վերդրված» կետադրական նշաններ (պարույկ, շեշտ, բացականչական նշան { ° } { ´ } { ´´ }) պարունակող շարքերը տրոհվում են որպես բազմաբառ բառանիշեր (multiword tokens). այսպես՝ *հնչո՞ւ* բառաձևում կունենանք երկու բառանիշ { հնչու } և { ° }; Բացառություն են ապաթարցը { ´ } և պատիվը { ´´ }, որոնք նախորդող գրանշանների հետ տրոհվում են որպես մեկ միասնական բառանիշ, օր.՝ *Ժաննա ղԱրկ*-ը հատույթավորվելու է որպես երեք բառանիշ՝ { Ժաննա } { ղ } { Արկ }:

2.3. Միմյանց հաջորդող հայերեն կետադրական նշանները՝ « , — տրոհվում են որպես անջատ բառանիշեր { » } { , } { — } : Միևնույն ժամանակ, կախման կետերը { ... } և բազմակետերը { ... } կետադրական մեկ նշան են, հետևաբար նաև մեկ բառանիշ, ոչ թե երեք կամ չորս առանձին կետերից բաղկացած արտահայտություն: Բացառություն են մի քանի նշաններից բաղկացած emoji, smiley տիպի շարքերը՝ { :) }, { :& }, { ^_^ }, որոնք դիտարկվում են որպես մեկ միասնական բառանիշ (այսինքն՝ կարևոր է այսպիսի գրանշանների միայն դասը): Այլ այբուբենների բազմանիշ կետադրական նշանները (?) նույնպես տրոհվում են { ? } { ! }:

2.4. Չակերտներում վերցված արտահայտություններին միության գծիկով (ենթամնայով) հաջորդող վերջավորությունները (թեքույթները) տրոհվում են, օր.՝ «*Երկիր Նաիրի*»-ից դեպքում կունենաք վեց բառանիշ՝ { « } { Երկիր } { Նաիրի } { » } { - } { ից } : Նույն կանոնը գործում է նաև համառոտագրությունների դեպքում՝ *1950 թ.-ին* դեպքում՝ հինգ բառանիշ՝ { 1950 } { թ } { . } { - } { ին }:

2.5. Թվանշատառային արտահայտությունները, որոնցում թվանշանին հաջորդում է միության գծիկ (ենթամնա) ու հայերեն տառեր, դիտարկվում են որպես մեկ միասնական բառանիշ, լինեն դրանք թվականներ, ածականներ, հապավումներ և այլն, օր.՝ { 1-ին }, { 2-րդ }, { 4-ը }, { 1000-ական }, { 1950-ականներին }, { 20-ամյակ }, { 1700-ամյա }, { ՏՈՒ-154Մ } : Նույն կերպ են տրոհվում հապավումներին միության գծիկով (ենթամնայով) հաջորդող վերջածանցները, թեքույթները, հմմտ.՝ { ՀՀԿ-ականներից }:

2.6. Թվանշանները { 265,459.00 }, նաև այնպիսիք, որոնք պարունակում են ստորակետ կամ միջակետ՝ որպես ամբողջի և մասի բաժանարար՝ { 2,15 }, { 2.15 }, կոտորակները՝ { 2/3 }, մաթեմատիկական կամ քիմիական բանաձևերը, էլ. փոստի { muster@muster.am }, կայքէջերի հասցեները { https://github.com }, թվիթների տիպի անունները { @gov_am } չեն տրոհվում, դիտարկվում են որպես մեկ ամբողջական

բառանիշ: Այսպիսի արտահայտությունների կառուցվածքի վերլուծությունն իմաստ չունի, կարևոր է միայն այս բառանիշերի դասը: Բացատ պարունակող թվանշանները, օր.՝ 20 000, ծանոթագրողների կողմից ձևաբան միավորվում են որպես մեկ բառանիշ՝ 20_000 (23B5 Unicode (hex)) նշանի միջոցով { 20_000 }, և բացատին հավելյալ ուղղագրական նշանակություն է վերագրվում:

2.7. Ժամանակ ցույց տվող թվանշանային արտահայտությունները՝ ժ. 20:55 կամ ժ. 20.55, մնում են մեկ բառանիշ՝ { 20:55 }, { 20.55 } : Նույն կերպ են վերլուծվում նաև ամիս-ամսաթվեր, տարեթվեր ցույց տվող թվանշանային արտահայտությունները՝ { 24.04.1965 }, { 24/04/1965 } :

2.8. Թվանշաններին նախորդող կամ հաջորդող հատուկ նշանները (ներառյալ՝ + կամ -), չափման միավորները, տերմիններ արտահայտող նշանները (կմ, \$, % և այլն) տրոհվում են անջատ բառանիշերի, եթե անգամ դրանց միջև բացատ չկա, օր.՝ { € } { 200 }, { 18,25 } { % }, { + } { 35 } { °C }, { 135 } { կմ/ժ } :

3. Վերոնշյալ կանոններով չնախատեսվող բոլոր դեպքերը (գծիկով կամ անջատ գրվող վերլուծական բառերը, մասնավորապես՝ հարադրությունները, կցական և կրկնավոր բարդությունները) հատույթավորվում են ուղղագրական կանոններին համապատասխան և տրոհվում են «բազմաբառ արտահայտությունների» (MWE, multiword expressions), օր.՝ { ինչ } { - } { որ }, { մեկ } { - } { մեկ }, { ժամանակ } { առ } { ժամանակ } և այլն:

ՏԵՔՍՏԻ ՏՐՈՂՈՒՄԸ ՆԱԽԱԴԱՍՈՒԹՅՈՒՆՆԵՐԻ

Նախադասությունների սահմանազատումը (sentence splitting) տեքստի հատույթավորման մեթենական համակարգերի համար ձևակերպվում է որպես հետևյալ երկու խնդրի լուծմանն ուղղված որոշման ընդունում¹⁵.

ա) արդյոք կետադրական նշանը տվյալ համատեքստում հուշում է նախադասության ավարտի մասին (սահմանազատի՞չ է արդյոք նշանը),

բ) արդյոք սահմանազատվել է՞ն տեքստում առկա բոլոր նախադասությունները:

Երկրորդ խնդիրը երբեմն ձևակերպվում է որպես տեքստում բոլոր այն դադարների բացահայտում, որոնք նախադասության սահմանները զատող մոդուլը ինչ-ինչ պատճառներով բաց է թողել, չի նշել¹⁶: Այն խոսքի ճանաչման հետազոտություններում ձևակերպվում է որպես «ստանդարտ (արդեն իսկ կետադրված) տեքստերում» նախադասությո-

¹⁵ Տե՛ս **Урюпина О.** Автоматическое разбиение текста на предложения для русского языка // Труды международной конференции «Диалог». М., 2008, էջ 539 // <http://www.dialog-21.ru/media/1803/83.pdf>

¹⁶ Տե՛ս **Кудинов А. С., Воропаев А. А., Калинин А. Л.** Высокоточный метод распознавания концов предложений // Труды международной конференции «Диалог». М., 2011, էջ 422-423, <http://www.dialog-21.ru/media/1438/37.pdf>

յան ավարտը հուշող «կետադրության բազմիմաստությունը վերացնելու» խնդիր (punctuation disambiguation) ի հակադրություն «նախադասության սահմանները որոշելու» խնդրի (sentence boundary detection), որը նույնական է հենց այդպիսի կետադրական նշանները բացահայտելու հետ¹⁷:

Ակնհայտ է, որ հուշումը, թե արդյոք տեքստում նշանը սահմանագատիչ է, այսինքն՝ արդյոք այն նշելու է նախադասության ավարտը, թե՛ ոչ, հնարավոր է քաղել այդ նշանի համատեքստից: Ակնհայտ է նաև, որ այդպիսի հուշումները տեքստի մեքենական մշակման համակարգերում կարելի է ձևակերպել որոշակի կանոնների միջոցով:

Կարևոր է, թե տեքստի տրոհված որ հատվածներն են գնահատվելու որպես նախադասություն: Խոսքն այս դեպքում նախադասության դասագրքային, ավանդական սահմանման մասին չէ, երբ այն ընկալվում է, օրինակ, որպես ամփոփ միտք ձևավորող, արտահայտող կամ հաղորդող և հնչերանգային ավարտվածություն ունեցող շարահյուսական անկախ միավոր՝ ստորոգական գործառնությամբ¹⁸: Տեքստի մեքենական մշակման համակարգերում նախադասությունը շատ ավելի լայն է ընկալվում. բառանիշերի շարք կամ կապակցություն, որն ավելի հաճախ է հանդիպում իրական, «ստանդարտ» տեքստերում, և որը, պայմանավորված համակարգին առաջադրված խնդրով, հարմար է գնահատել որպես մեկ անկախ ամբողջություն: Պարզ է, որ նմանատիպ շարքերը միշտ չէ, որ իմաստային ավարտվածություն ունեն: Ընդհակառակը, դրանք երբեմն կարող են նաև ոչ ավարտուն հատվածներ լինել կամ հատվածներ, որոնք տեքստում «լուսանցքային» են (մատենագիտական ցանկերի կամ աղյուսակների տողեր, վերնագրեր, թվարկումներ և այլն):

«Հայերենի ծառադարանում» նախադասությունների սահմանագատումն ընկալվում է որպես տեքստի տրոհում այնպիսի հատվածների, որոնք հնարավորինս մոտ են նախադասության դասագրքային պատկերացումներին: Ենթադրվում է, որ նախադասության սահմանները տեքստում հիմնականում ակնհայտ են, և դրանք կարելի է ձևակերպել ինտուիտիվ հասկանալի կանոնների միջոցով: «ՀայՆիշ» մոդուլում այս մոտեցումներն արտացոլվել են հետևյալ երեք սկզբունքների տեսքով.

ա) հատույթավորման ենթակա տեքստի սկիզբը համընկնում է առաջին նախադասության սկզբի հետ, տեքստի ավարտը՝ վերջին նախադասության ավարտի հետ,

¹⁷ Տե՛ս **Mark Stevenson, and Robert Gaizauskas**. Experiments on Sentence Boundary Detection. In *Proceedings of the sixth conference on Applied natural language processing (ANLC)*, pages 84-89, Seattle, Washington. 2000, էջ 85, <http://www.aclweb.org/anthology/A00-1012>

¹⁸ Տե՛ս **Ս. Աբրահամյան**, Ժամանակակից հայերենի քերականություն, Եր., 1975, էջ 265, նաև՝ **Ս. Աբրահամյան, Ն. Պառնասյան, Հ. Օհանյան, Խ. Բաղիկյան**, Ժամանակակից հայոց լեզու, Շարահյուսություն, հ. 3, Եր., 1976, էջ 128, **Հ. Պետրոսյան**, նշվ. աշխ., էջ 476-478:

բ) նախադասությունը միշտ սկսվում է մեծատառով,

գ) պարբերության ավարտը միշտ չէ, որը համընկնում է նախադասության ավարտի հետ (տե՛ս ուրիշի ուղղակի խոսքի տրոհման կանոնները):

Այս սկզբունքների հիման վրա «ՀայՆիշ»-ում ըստ էության ձևայնացվել է հայերենում նախադասությունների նախնական սահմանագատման հետևյալ կանոնը.

4. նախադասության սահմանն անցնում է սահմանագատիչ նշանից հետո՝ հաջորդող մեծատառից կամ նոր պարբերությունից առաջ:

Այս մոտեցմամբ՝ հայերենում նախադասության համար սահմանագատիչ են վերջակետը { : }, կախման կետերը { ... } և բազմակետերը { } : Ընդ որում, գրանշային բոլոր այն շարքերը, որոնք սկսվում են մեծատառով և չեն ավարտվում սահմանագատիչ կետադրական նշաններից ոչ մեկով (վերնագրեր, կոչեր, պարբերականների, ստեղծագործությունների անվանումներ, թվարկումներ, աղյուսակների տողեր և այլն), «ՀայՆիշ» մոդուլը կրկին տրոհելու է որպես նախադասություն, եթե պարբերության ավարտը համընկնում է այդպիսի կտորի ավարտի հետ:

Ի տարբերություն կյուրեղա- կամ լատինատառ տեքստերի, երբ սահմանագատիչ «լրիվ դադարի կետը» (վերջակետը) հանդիպում է նաև հապավումներում, կայքէջերի, էլ. փոստի հասցեներում, ամսաթվերում, կոտորակային թվանշաններում և այլն, հայերենում վերջակետը իրական տեքստերում հանդիպում է առավելապես թվանշանային արտահայտություններում (օր.՝ ժ. 12:45-ին), ինչը հեշտացնում է այն որպես սահմանագատիչ բացառող կանոնի մշակումը:

Նախադասությունների սահմանագատման հմ. 4. կանոնը գործում է նաև մեջբերումները և ուրիշի ուղղակի խոսքը նկարագրելիս.

5. հեղինակային խոսքը, լինի նախադաս, միջադաս թե հետադաս, չի առանձնացվում ուրիշի ուղղակի՝ մեջբերվող խոսքից:

UD ծառադարաններում հեղինակային ու մեջբերվող խոսքը ծանոթագրվում են շարահյուսական հատուկ կապի միջոցով (parataxis), որը թույլ է տալիս շարահյուսական վերլուծության ընթացքում ապահովել նախադասության իմաստային ավարտունությունը: Հայերենում անջատման գծով և միջակետով կետադրված ուրիշի ուղղակի խոսքի հատուկավորումը հետևյալ տեսքն ունի (նախադասության սահմանը նշվում է | ուղղաձիգ գծով)¹⁹.

Շրջվեց:/ Մուրադենց Վարանցովն էր՝ պապիրոսը բերանի անկյունում:/

— Մարդ աստճո,— շնջաց,— բարյուսախառն միանգամից էղքան վատ բան բերանդ ո՞նց գորեց ասել:/

¹⁹ Օրինակներն ըստ՝ Հացի փորձություն: [Պատմվածքներ, վիպակ] / Վ. Ջ. Սարգսյան: Եր., Յավրուհրատ, 2015:

— *Ուրեմն դու չգիտեսի՞ր:— Դեռ չէր հավատում Վարանցովը:— Գերեզմանի համար քեզ բան չէ՞ն ասել.../ Էս գյուղում քեզանից բացի ուրիշ գերեզմանափոր էլ կա .../*

Մանրամասնող կանոնի անհրաժեշտություն է առաջանում,

5.1. երբ տեքստում հեղինակի խոսքն ավարտվում է միջակետով կամ բութով, իսկ ուրիշի ուղղակի խոսքը մեջբերվում արդեն նոր պարբերությունից, անջատման գծով և մեծատառով, նոր պարբերությունը սահմանագատիչ չի համարվում, սակայն բառանիշր, որով սկսվում է այն, ծառայարանում հավելյալ ծանոթագրվում է նոր պարբերության առկայությունը հուշող NewPar=Yes հատկանիշով:

Նկարագրության միօրինակությունը պահպանելու համար այսպիսի դեպքում մեքենական մոդուլը առաջնահերթ է համարում սահմանագատումը ոչ թե 4. հիմնական կանոնով, երբ նոր պարբերությունը նաև նոր նախադասության սկիզբ էր, այլ արդեն 5.1. մանրամասնող կանոնով, օր.

Հենվեց բահին ու գիշերվա երազը ծայրից ծայր ջրին պատմեց, մեղավորի նման խոստովանեց ու խնդրեց.[]

— *[NewPar=Yes] Երագիս չարը տար ու բարին թող, ջրիկ ջան: / Չարը խափանիր, ջրիկ ջան: /*

Տեքստի տրոհման նույն սկզբունքը գործում է նաև ուրիշի ուղղակի խոսքը չակերտներով մեջբերելու դեպքում.

Հետո լեզուն բացվեց. «Ախր, այ Գևորգ,— ասաց,— հագինդ նախագահի նվիրած կոստյումն է:» /

«Ի՞նչ է կատարվում»,— նորից հարցնում էին ու դարձյալ նրանց չէին լսում: /

«Տո, նախագահի մերն էլ, քո մերն էլ,— համբերությունը հատած գոռաց,— դու ցեխը լցրու, ցեխը...» /

Հավաքե՛ց, հավաքե՛ց, մի բուռ համարձակություն հավաքեց ու իրեն նրա ձիու ոտքերի տակ տվեց՝ «Տեր ամենակարող,— աղաչեց,— դուն ազատես իմ հերն ու աղբերիկս:» /

Ընդ որում, հնարավոր են դեպքեր, երբ բացող չակերտը մի նախադասության մեջ է, իսկ փակողը՝ հաջորդում (քանի որ դրանց միջև կա սահմանագատիչ նշան): Նման մոտեցումը թույլ է տալիս շարահյուսորեն ավարտուն կառույցներ ունենալ:

Վեպի մասին «Հայ վեպի պատմություն» գրքի հանձնարարականում գրված է, որ «վեպը արվեստի ինտելեկտուալացման ամենաբարձր աստիճանն է: / Վեպը էպիկական ստեղծագործություն է, որի մեջ պատումը կենտրոնացված է առանձին անհատի ճակատագրի վրա, նրա բնավորության և ինքնագիտակցության ձևավորման և զարգացման վրա:» /

«Վեպ», Վիքիպեդիա, <https://hy.wikipedia.org/wiki/%D5%8E%D5%A5%D5%BA>

Եթե չակերտներում մեջբերվում է անվանում (գեղարվեստական կամ գիտական երկերի վերնագրեր, թերթերի անուններ և այլն), որում


կրկին առկա են սահմանագատիչ նշաններ, ծանոթագրողները առանձնացված նախադասությունները (տրոհված են երկու || ուղղաձիգ գծով) ձեռքով միավորում են մեկ նախադասության մեջ: Այլ կերպ ասած՝ առաջնայնությունը տրվում է նախադասության կառուցվածքը ամբողջական պահելու հանգամանքին:

Խաչատուր Աբովյանի «Վերք Հայաստանի: // Ողբ հայրենասեր»-ի վեպը հրատարակվել է 1858 թ.:/

Բերենք UD ձևաչափով ծանոթագրված նախադասության մեկ օրինակ²⁰, որը CoNLL-U նիշքում հետևյալ տեսքը կունենա.

```
# text = Հայ ժողովրդի մշակույթի ոչ մի բնագավառ այնքան հարուստ ու բազմապիսի դրսևորումներ չի ունեցել, ինչպես ճարտարապետությունը:
1 Հայ հայ ADJ _ Degree=Pos 2 amod _ _
2 ժողովրդի ժողովուրդ NOUN _ Animacy=Hum|Case=Dat|Definite=Ind|Number=Sing 3 nmod:poss _ _
3 մշակույթի մշակույթ NOUN _ Animacy=Nhum|Case=Dat|Definite=Ind|Number=Sing 6 nmod:poss _ _
4 ոչ ոչ PART _ _ 6 det _ _
5 մի մի DET _ _ 4 fixed _ _
6 բնագավառ բնագավառ NOUN _ Animacy=Nhum|Case=Nom|Definite=Ind|Number=Sing 13 nsubj _ _
7 այնքան այնքան ADV _ Distance=Dist|PronType=Dem 8 advmod _ _
8 հարուստ հարուստ ADJ _ Degree=Pos 11 amod _ _
9 ու ու CCONJ _ _ 10 cc _ _
10 բազմապիսի բազմապիսի ADJ _ Degree=Pos 8 conj _ _
11 դրսևորումներ դրսևորում NOUN _ Animacy=Nhum|Case=Nom|Definite=Ind|Number=Plur 13 obj _ _
12 չի եմ AUX _ Aspect=Imp|Mood=Ind|Number=Sing|Person=3|Polarity=Neg|Tense=Pres|VerbForm=Fin 13 aux _ _
13 ունեցել ունեցել VERB _ Aspect=Perf|Subcat=Tran|VerbForm=Part|Voice=Act 0 root _ SpaceAfter=No
14 , , PUNCT _ _ 16 punct _ _
15 ինչպես ինչպես ADP _ AdpType=Prep 16 case _ _
16 ճարտարապետությունը ճարտարապետություն NOUN _ Animacy=Nhum|Case=Nom|Definite=Def|Number=Coll 8 obl _ SpaceAfter=No
17 :: PUNCT _ _ 13 punct _ _
```

17 բառանիշից բաղկացած այս նախադասությունն արտապատկերվում է հետևյալ կերպ.



Ծանոթագրված տեքստի արտապատկերումը կախումների շարահյուսական ծառի տեսքով²¹:

²⁰ Օրինակը համեմատության նպատակով վերցված է՝ **Լ. Հովսեփյան**, նշվ. աշխ., էջ 156 (այն UNL ձևաչափով ծանոթագրված նախադասության հասանելի միակ օրինակն է):

²¹ Օգտագործվել է արտապատկերման Annodoc (<http://spysalo.github.io/annodoc/>) մոդուլը:

ՄՈԴՈՒԼԻ ԿԻՐԱՌԵԼԻՈՒԹՅՈՒՆԸ

Տեքստի հատույթավորման «ՀայՆիշ» մոդուլը մշակվել է «Հայերենի ծառադարան» նախագծում բառերի և նախադասությունների սահմանները որոշելու խնդիրը մեքենացնելու նպատակով: Ապա այն առանձնացվել է որպես առանձին մոդուլ Python ծրագրավորման լեզվով և հրապարակվել է GitHub-ում:

Կանոնների վրա հիմնված այս մոդուլի հիմնական թերությունը բնորոշ է նմանատիպ բոլոր համակարգերին. իրական հնարավոր բոլոր դեպքերի նկարագրության համար անհրաժեշտ է անընդհատ մանրամասնել կանոնները: Ի տարբերություն արդեն իսկ ծանոթագրված տվյալների վրա հիմնվող մեքենական ուսուցման ալգորիթմների՝ կանոնների վրա հիմնված «ՀայՆիշ» մոդուլը հնարավոր չէ փոփոխել տվյալների ծանոթագրության ընթացքում, ինչը երբեմն ստեղծում է ծանոթագրողների միջամտության անհրաժեշտություն՝ ձևաբանական կամ շարահյուսական նկարագրությունը միօրինակ պահելու նպատակով: Այս առումով տվյալահենք ալգորիթմները շատ ավելի ճկուն են, դրանք հնարավոր է վերաուսուցանել նոր տվյալների ավելացմանը զուգընթաց:

Մյուս կողմից, կանոնների վրա հիմնվող մոդուլը կիրառելի է տեքստերի նախնական, առաջնային մշակման համար՝ առանց լեզվաբանական հավելյալ ցանկերի: Այսպիսի մոտեցումը, ինչպես և ցույց տրվեց նախորդ հատվածներում, երբեմն տալիս է արդյունքներ, որոնք հեռու են բառի և նախադասության ավանդական, լեզվաբանական ընկալումներից, սակայն ունի մեկ հիմնական առավելություն. պետք չեն մասնագետների կողմից նախապես կազմվող արտաքին ամբողջական կամ անընդհատ թարմացվող տարաբնույթ ցանկեր, որոնք հատույթավորման ընթացքում մեկ միասնական բառանիշ կպահեն հապավումները ({ Ֆր. }, { մ.թ.ա. }, զծիկով կամ անջատ գրվող բառերը ({ ինչ-որ }, { ի վերուստ }, { ՀՀԿ-ական }, { 20-ամյա }) և այլն:

Տեքստի հատույթավորման «ՀայՆիշ» մոդուլում կիրառված լուծումները կարող են օգտակար լինել հայերենում բառանջատման ու նախադասությունների սահմանագատման խնդրին այլ մոտեցումներ մշակելու համար:

Բանալի բառեր – *բնական լեզվի մշակում, համընդհանուր կախվածություններ, ծառադարան, շարահյուսական կախումների ծառեր, ծառերի բանկ, կորպուս, գրային համակարգ, հատույթավորում, կետադրություն, բառանջատում, բառանիշավորում, բառանիշ, նախադասություն*

МАРАТ ЯВРУМЯН – *Автоматическая сегментация текста в проекте Трибанк восточноармянского языка UD_ARMENIAN–ArmTDP.* – Сегментация текста на слова и предложения – необходимый начальный этап его автоматической обработки. Последующие стадии анализа существенно образом зависят от принятых решений о делении текста на слова или минимальные линейные компо-

ненты — токены. В проекте Трибанк восточноармянского языка был разработан автоматический модуль сегментации текста, основанный на небольшом наборе базовых правил, и проведена сегментация текста объёмом более 36 тыс. словоупотреблений. Результаты были проверены вручную, а полученные данные использованы в качестве обучающей выборки для токенизации и распознавания концов предложения методом машинного обучения в рамках создания синтаксического парсера восточноармянского языка.

Ключевые слова: *обработка естественного языка, корпус, сегментация, токенизация, графематика, универсальные зависимости, банк синтаксических деревьев, сегментация, конец предложения*

MARAT YAVRUMYAN – *Tokenization and Word Segmentation in the UD_ARMENIAN-ArmTDP TREEBANK.* – Word segmentation and sentence splitting are a necessary initial stage of natural language processing. The subsequent stages of the analysis essentially depend on the decisions made about splitting the text into tokens and the detection of sentence boundaries. In the project of UD_Armenian-ArmTDP treebank a tokenization module was developed based on a small set of basic rules, then more than 36K text forms were tokenized, the results were checked manually, and the data was used as a training set for tokenization and word segmentation in the framework of the task of creating a syntactic parser for Eastern Armenian.

Key words: *natural language processing, Universal dependencies, treebank, corpora, segmentation, tokenization, sentence boundary detection*

Ներկայացվել է՝ 03.07.2019

Գրախոսվել է՝ 10.09.2019

Ընդունվել է տպագրության՝ 28.11.2019