

Formal Model of Explanatory Trilingual Terminology Dictionary

Alona Dorozhynska

Ukrainian Lingua-Information Fund of NAS of Ukraine, 3, Holosiivskyi avenue, Kyiv, 03039, Ukraine

Abstract

The object of research is the academic trilingual (Ukrainian-Russian-English) "Dictionary of Ukrainian biological terminology" (SUBT) [1]. This dictionary is an authoritative terminographic work that embraces the normative general scientific and widely used and narrowly specialized terminology of biological sciences, recorded in encyclopedic, general language and special dictionaries, in scientific, popular science, educational and informative literature. The dictionary is published in small editions in traditional paper form; it is very popular among users - scientists, graduate students and students of biological specialties.

The digital version of the dictionary in pdf-format was used in the research. The research process included the construction of a formal model of the lexicographic system of SUBT, the analysis of which provides an opportunity to generalize it to other terminological dictionaries. The developed model of the lexicographic system of SUBT was used to create a representation of the text of the Dictionary by means of XML markup language, which was used to convert the pdf-file of SUBT into XML-file, which completely reproduces the formal structure of the lexicographic system.

The presence of an XML file allows you to build a database according to the structure of the dictionary article. The XML file is proposed to be used as an intermediary between the paper version of the dictionary and its implementation as an online lexicographic system. The possibility of building a formal model for dictionaries of this type is considered.

Keywords¹

Computer lexicography, lexicographic system, parsing, XML, database, digital space, website.

1. Introduction

As you know, the dictionary consists of dictionary articles, is a certain set of them. If the dictionary is built according to the canons of lexicographic science, then it has a certain structure to which all its dictionary articles are subject. Usually the structure of dictionary articles is described in the preface to the dictionary. But between different dictionary entries of the same dictionary there are many connections, relations, reflections, which reflect the content of the subject area that is the object of lexicography, and these relations are usually implicit. However, they are very important for users and those who want to use the dictionary to conduct their own research and create new dictionaries. Partially mentioned structural vocabulary effects are described in the works [2, 4, 6]. General theory of dictionary structures - the theory of lexicographic systems was created by V. A. Shirokov in the 90s of last century; The most complete presentation of this theory and its applications is published in the seven-volume edition "Linguistic and Information Studies", which is available for free on the website of the Ukrainian Linguistic Portal at <https://www.ulif.org.ua/publication>. In our work we will follow the principles of this theory.

It is important to distinguish between the most formal model and the XML scheme (coding scheme). That is, it is necessary to consider the form and content of lexical information in the abstract, regardless of the requirements and restrictions imposed on its final presentation as a coded or printed object [7, 8]. This process is important, because dictionaries can be coded not only for the purposes of publication in

COLINS-2021: 5th International Conference on Computational Linguistics and Intelligent Systems, April 22–23, 2021, Kharkiv, Ukraine
EMAIL: alonochkatkachyk@gmail.com (A.Dorozhynska)

ORCID: 0000-0001-6554-6731 (A.Dorozhynska)



© 2021 Copyright for this paper by its authors.

Use permitted under Creative Commons License Attribution 4.0 International (CC BY 4.0).

printed (book) or electronic form (website), but also to create computational lexicons. Therefore, it is very important to develop a model that can later be transformed into a variety of alternative formats [3]. In this paper, we outline the following stages:

1. Lexicographic system (L-system) development of dictionary structure

2. Marking the text of the Dictionary with XML tags according to the structure of its L-system (XML document)

Using the examples of dictionary articles of the selected dictionary, we will demonstrate how the XML schema can be applied to any dictionary article. Due to its generality, we believe that our model can serve as a basis for presenting, combining and extracting information not only from dictionaries of the same type, but also from a wide range of terminological dictionaries [5].

2. The steps

2.1. Lexicographic system development of Dictionary of Ukrainian biological terminology (SUBT)

We introduce the notation: $A \rightarrow B$ it will mean, that $A \supseteq B$. Then, following the theory of lexicographic systems [2], the structure of the L-system of SUBT is presented in the form:

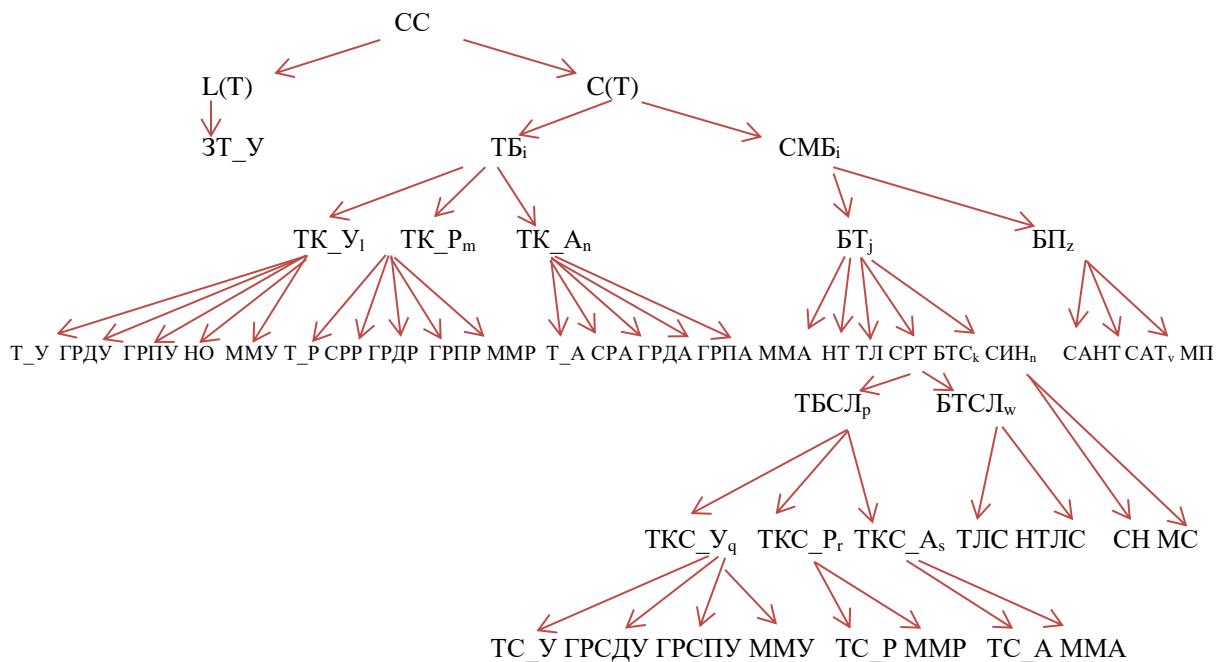


Figure 1. General scheme of the dictionary article of the SUBT

In scheme 1, the structural elements mean the following:

СС — dictionary article text	TCK_Y _q — terminological complex of phrases ukr.
ЗТ_У — the title term is Ukrainian	TC_U — terminological phrase in the Ukrainian language
ТБ_i — terminological block	ГРСДУ — grammatical remark to the phrase
ТК_У₁ — terminol. complex ukr.	ГРСПУ — grammatical remark after the phrase
Т_У — the term is Ukrainian	ММУ — language marker (ukr)
ГРДУ — grammatical remark to the term	TCK_P _r — terminological complex of words. Rus.
ГРПУ — grammatical remark after the term	TC_P — terminological phrase in Russian
НО — homonym number	MMP — language marker (in Russian)
ММУ — language marker (ukr)	TCK_A _s — terminological complex of phrases in English.
ТК_Р_m — terminol. complex of rus.	TC_A — terminological phrase in English
Т_Р — the term is Russian	MMA — language market
ГРДР — grammatical remark to the term	БТСЛ_p — block of interpretations of phrases
ГРПР — grammatical remark after the term	ТЛС — interpretation
ММР — language marker (rus)	HTC — phrase interpretation number
CPP — semantic trailer	СИН_t — synonymous block
ТК_A_n — terminol. English complex	CH — synonym
Т_A — English term	MC — synonym marker (Син.)
ГРДА — grammatical remark to the term	БП_z — link block
ГРПА — grammatical remark after the term	САНТ — sender
ММА — language marker	CAT _v — recipient (can be several)
СРА — semantic trailer	МП — link token (<i>див.</i>)
СМБ_i — semantic block	
БТ_j — interpretation block	
НТ — interpretation number	
ТЛ — interpretation	
CPT — semantic trailer to tl.	
БТС_k — block of terminological phrases	
ТБСЛ_p — terminological block of phrases	

Lexical information in dictionary articles can be represented in the form of a tree structure, which largely reflects the natural hierarchical organization of entries in printed dictionaries. Consider the examples in the notation of the scheme:

Example 1.

ву#са, -ів, мн., одн. вус, -а (рос. усы#, ед. ус., англ. whisker (у тварин), tendril (у рослин), moustache (у людини), antenna (у комах)) 1. Загальна назва розміщених біля рота чутливих волосин (вібрисів) у ссавців та щетинкоподібного пір'я у птахів, деякі дотикові утвори у безхребетних тварин; 2. Надzemні витки прикріплювальні пагони у рослин.

Marking	Representation in the SS
ТБ	ву#са, -ів, мн., одн. вус, -а (рос. усы#, ед. ус., англ. whisker (у тварин), tendril (у рослин), moustache (у людини), antenna (у комах))
ЗТ	ву#са
ТК_У ₁	ву#са, -ів, мн.

ММУ	укр.
Т_У	ву#са
ГРПУ	-ів, мн.,
ТК_У ₂	одн. вус , -а
ММУ	укр.
Т_У	вус
ГРДУ	одн.
ГРПУ	-а
ТК_Р ₁	рос. усы#
ММР	рос.
Т ^Р	усы#
ТК_Р ₂	ед. ус
ММР	рос.
Т_Р	ус
ГРДР	ед.
ТК_А ₁	англ. whisker (у тварин)
ММА	англ.
Т ^А	whisker
СРА	у тварин
ТК_А ₂	tendril (у рослин)
ММА	англ.
Т ^А	tendril
СРА	у рослин
ТК_А ₃	moustache (у людини)
ММА	англ.
Т ^А	moustache
СРА	у людини
ТК_А ₄	antenna (у комах)
ММА	англ.
Т ^А	antenna
СРА	у комах
СБ	1. Загальна назва розміщених біля рота чутливих волосин (вібрисів) у ссавців та щетинкоподібного пір'я у птахів, деякі дотикові утвори у безхребетних тварин; 2. Надземні виткі прикріплювальні пагони у рослин.
БТ ₁	1. Загальна назва розміщених біля рота чутливих волосин (вібрисів) у ссавців та щетинкоподібного пір'я у птахів, деякі дотикові утвори у безхребетних тварин
НТ	1
ТЛ	Загальна назва розміщених біля рота чутливих волосин (вібрисів) у ссавців та щетинкоподібного пір'я у птахів, деякі дотикові утвори у безхребетних тварин
БТ ₂	2. Надземні виткі прикріплювальні пагони у рослин.
НТ	2
ТЛ	Надземні виткі прикріплювальні пагони у рослин.

In the example, there is only one terminology block and one semantic block, respectively. It was found

that in dictionary articles there are as many terminological blocks as semantic ones and vice versa. There are two Ukrainian complexes in the terminological block. Presented as: **вус**, -ів, мн.; одн. **вус**, -а. In the semantic block there can be some interpretations in an example of them two are found: 1. Загальна назва розміщених біля рота чутливих волосин (вібрисів) у ссавців та щетинкоподібного пір'я у птахів, деякі дотикові утвори у безхребетних тварин; 2. Надземні витки прикріплювальні пагони у рослин.

Example 2.

новонаро#джений 1. *прикм.* (рос. новорождённый, англ. neonatus, neonate) який недавно або тільки що народився; 2. *ім., -ого* (рос. новорождённый, англ. newborn, infant) людина, яка недавно народилася.

Marking	Representation in the SS
ТБ ₁	новонаро#джений 1. <i>прикм.</i> (рос. новорождённый, англ. neonatus, neonate)
ЗТ	новонаро#джений
ТК_U	новонаро#джений 1. <i>прикм.</i>
ММУ	укр.
Т_У	новонаро#джений
ГРПУ	<i>прикм.</i>
ТК_P	рос. новорождённый
ММР	рос.
Т ^P	новорождённый
ТК_A	англ. neonatus
ММА	англ.
Т ^A	neonatus
СБ ₁	1. який недавно або тільки що народився;
БТ ₁	1. який недавно або тільки що народився;
НТ	1
ТЛ	який недавно або тільки що народився;
ТБ ₂	<i>ім., -ого</i> (рос. новорождённый, англ. newborn, infant)
ТК_U	новонаро#джений <i>ім., -ого</i>
ММУ	укр.
Т_У	новонаро#джений
ГРПУ	<i>ім., -ого</i>
ТК_P	рос. новорождённый
Т_P	новорождённый
ММР	рос.
ТК_A ₁	англ. newborn
Т_A	newborn
ММА	англ.
ТК_A ₂	infant
Т_A	infant
ММА	англ.
СБ ₂	2. людина, яка недавно народилася.
БТ ₂	2. людина, яка недавно народилася.
НТ	2.

ТЛ

людина, яка недавно народилася.

The example reveals two terminological blocks and two semantic ones, respectively. The first terminological block is complete, it consists of Ukrainian, Russian and English complexes. The second block is cut. The terminological block Ukrainian in both complexes has a common Ukrainian term, which is the title word. Semantic blocks, respectively, consist only of interpretations.

Example 3.

ацидофі#льний (рос. ацидофи#льный, англ. acidophilic) 1. Який має здатність забарвлюватися кислими барвниками; **ацидофі#льні органі#зми** див. **органі#зм: органі#зми ацидофі#льні**. Син. **кислотолю#бний**; 2. Який росте тільки в кислому середовищі.

Marking	Representation in the SS
ТБ	ацидофі#льний (рос. ацидофи#льный, англ. acidophilic)
ЗТ	ацидофі#льний
TK_U	ацидофі#льний
ММУ	укр.
T_U	ацидофі#льний
TK_P	рос. ацидофи#льный
ММР	рос.
T ^P	ацидофі#льний
TK_A	англ. acidophilic
ММА	англ.
T ^A	acidophilic
СБ	1. Який має здатність забарвлюватися кислими барвниками; ацидофі#льні органі#зми див. органі#зм: органі#зми ацидофі#льні . Син. кислотолю#бний ; 2. Який росте тільки в кислому середовищі.
БТ ₁	1. Який має здатність забарвлюватися кислими барвниками;
НТ	1
ТЛ	Який має здатність забарвлюватися кислими барвниками;
БТ ₂	2. Який росте тільки в кислому середовищі.
НТ	2
ТЛ	Який росте тільки в кислому середовищі.
СИН	Син. кислотолю#бний
СН	кислотолю#бний
МС	Син.
БП	ацидофі#льні органі#зми див. органі#зм: органі#зми ацидофі#льні .
САНТ	ацидофі#льні органі#зми
CAT	органі#зм
МП	див.

The semantic block can be filled with blocks of terminological phrases, synonyms, blocks of references. Terminological blocks can be several, they can be presented in one or two complexes. The examples illustrate some variants of the structure in the notation of the scheme.

2.2. Marking the text of the Dictionary with XML tags according to the structure of its L-system (XML document)

The next stage is the automatic conversion of the lexicographic structure of the dictionary into an XML document. However, it is obvious that the XML file explains and stores all the structural elements we have identified and the relationships between them. This is done using a special software procedure developed by us to automatically mark the text of the dictionary. The marking algorithm is developed based on polygraphic features of text identification of structural elements of the L-system (boundaries of the dictionary article (paragraphs), special symbols, positional characteristics, changes of language, fonts, case of letters, etc.).

XML dictionary article schema (SS)

```
<СС> Словникова стаття
    <ЗТУ>заголовний термін український</ЗТУ>
    <ТБ номер=p> Термінологічний блок
        <ТК_У номер=i> український термінологічний комплекс
            <ТУ> Термін український</ТУ>
            <НО> Номер омоніма</НО>
            <ГР> Граматична ремарка</ГР>
            <ММУ> укр.</ММУ>
        </ТК_У>
        <ТК_Р номер=j> російський термінологічний комплекс
            <ТР> Російський термін</ТР>
            <СР> Семантична ремарка</СР>
            <ГР> Граматична ремарка</ГР>
            <ММР> рос.</ММР>
        </ТК_Р>
        <ТК_А номер=k> англійський термінологічний комплекс
            <ТА> Термін англійський</ТА>
            <СР> Семантична ремарка</СР>
            <ГР> Граматична ремарка</ГР>
            <ММА> англ.</ММА>
        </ТК_А>
    </ТБ>
    <СМВ номер=p>
        <БТ номер=m> Блок тлумачення
            <ТЛ> Тлумачення </ТЛ>
            <СРТ> Семантична ремарка </СРТ>
            <СИН номер=n> Синонімічний блок
                <ТУ> термін</ТУ>
                <ТСУ> термін</ТСУ>
                <МС> Син.</МС>
        </СИН номер=n>
    </БТ>
    <БТС номер=l> Блок термінологічних словосполучень
        <ТБс номер=t> Термінологічний блок словосполучення
            <ТКС_У номер=f> Український термінологічний комплекс словосполучення
```

```

<TCy> Термологічне словосполучення</TCyp> Термологічне словосполучення</TCp>
    <ГРС> Граматична ремарка</ГРС>
    <ММР> Маркер мови</ММР>
</TKC_P>
<TKC_A номер =h> Англійський термінологічний комплекс словосполучення
    <TCp> Термологічне словосполучення</TCp>
    <ГРС> Граматична ремарка</ГРС>
    <ММА> Маркер мови</ММА>
</TKC_A>
</ТБс>
<БТсл номер =v> Блок тлумачення словосполучення
    <ТЛс> Тлумачення до словосполучення</ТЛс>
</БТсл>
</БТС>
<БП> Блок посилань</БП>
</СМБ>
</СС>

```

According to the scheme, all dictionary articles were marked. Consider the labeling by example 1,2.

Example 1

СС> <текст_СС> **ву#са**, -ів, мн., одн. **вус**, -а (рос. усы#, ед. ус., англ. whisker (у тварин), tendril (у рослин), moustache (у людини), antenna (у комах)) 1. Загальна назва розміщених біля рота чутливих волосин (вібрисів) у ссавців та щетинкоподібного пір'я у птахів, деякі дотикові утвори у безхребетних тварин; 2. Надземні виткі прикріплювальні пагони у рослин. <текст_СС>

```

<ТБ> <текст_ТБ> ву#са, -ів, мн., одн. вус, -а (рос. усы#, ед. ус., англ. whisker (у тварин), tendril (у рослин), moustache (у людини), antenna (у комах))</текст_ТБ>
<ТК номер='1'_У>
    <T_U> ву#са</T_U>
    <ГРПУ> -ів, мн. </ГРПУ>
    <ММУ> укр. </ММУ>
</ТК_У>
<ТК номер='2'_У>
    <T_U> вус</T_U>
    <ГРПУ> -а</ГРПУ>
    <ГРДУ> одн.</ГРДУ>
    <ММУ> укр. </ММУ>
</ТК_У>
<ТК номер='1'_Р>
    <T_P> усы#</T_P>
    <ММР> рос. </ММР>

```

```

</TK_P>
<TK номер='2'_P>
    <T_P> ус</T_P>
    <ГРДР> ед.</ГРДР>
    <ММР> posc. </ММР>
</TK_P>
<TK номер='1'_A>
    <T_A> whisker</T_A>
    <CP> у тварин</CP>
</TK_A>
<TK номер='2'_A>
    <T_A> tendril</T_A>
    <CP> у рослин</CP>
    <ММА> англ. </ММА>
</TK_A>
<TK номер='3'_A>
    <T_A> moustache</T_A>
    <CP> у людини</CP>
    <ММА> англ. </ММА>
</TK_A>
<TK номер='4'_A>
    <T_A> antenna</T_A>
    <CP> у комах</CP>
    <ММА> англ. </ММА>
</TK_A>
</ТБ>
<СМБ>

<БТ номер='1'>
    <ТЛ> Загальна назва розміщених біля рота чутливих волосин (вібрисів) у ссавців та
щетинкоподібного пір'я у птахів, деякі дотикові утвори у безхребетних тварин; </ТЛ>
</БТ>
<БТ номер='2'>
    <ТЛ> Надземні виткі прикріплювальні пагони у рослин.</ТЛ>
</БТ>
</СМБ>
</СС>

```

Example 2

```

<СС>
    <текст_СС> новонаро#джений 1. прикл. (рос. новорождённый, англ. neonatus, neonate) який
недавно або тільки що народився; 2. im., -ого (рос. новорождённый, англ. newborn, infant) людина,
яка недавно народилася. </текст_СС>
    <ЗТ> новонаро#джений </ЗТ>
    <ТБ номер='1'>
    <тест_ТБ> новонаро#джений 1. прикл. (рос. новорождённый, англ. neonatus, neonate) </тест_ТБ>
        <TK_У номер='1'>
            <T_У> новонаро#джений </T_У>
            <ГРПУ> прикл. </ГРПУ>
            <ММУ> укр. </ММУ>

```

```

        </TK_U>
        <TK_P номер='1'>
            <TP> новорождённый </TP>
            <MMP> ros. </MMP>
        </TK_P>
        <TK_A номер='1'>
            <T_A> neonatus </T_A>
            <MMA> англ. </MMA>
        </TK_A>
        <TK_A номер='2'>
            <T_A> neonate </T_A>
            <MMA> англ. </MMA>
        </TK_A>
    </ТБ>
    <ТБ номер='2'>
        <тест_ТБ> 2. i.m., -ого (ros. новорождённый, англ. newborn, infant) </тест_ТБ>
        <TK_U номер='1'>
            <T_U> новонаро#джений </T_U>
            <ГРПУ> i.m. </ГРПУ>
            <ГРПУ> -ого </ГРПУ>
            <ММУ> укр. </ММУ>
        </TK_U>
        <TK номер='1'_P>
            <T_P> новорождённый </T_P>
            <MMP> ros. </MMP>
        </TK_P>
        <TK_A номер='1'>
            <T_A> newborn </T_A>
            <MMA> англ. </MMA>
        </TK_A>
        <TK_A номер='2'>
            <T_A> infant </T_A>
            <MMA> англ. </MMA>
        </TK_A>
    </ТБ>
    <СМБ номер='1'>

        <БТ номер='1'>
            <HT>1</HT>
            <ТЛ> який недавно або тільки що народився; </ТЛ>
        </БТ номер='1'>
    </СМБ>
    <СМБ номер='2'>
        <БТ номер='2'>
            <HT>2</HT>
            <ТЛ> людина, яка недавно народилася. </ТЛ>
        </БТ номер='2'>
    </СМБ>
</CC>

```

The transition to an XML document is due to the need to define author tag sets and attribute names. Document XML structures can also be nested, providing any level of hierarchy, as long as the rules for

embedding XML documents are followed. XML documents can contain any optional grammar descriptions of the document so that other programs can check its structure. The XML representation of the dictionary obtained in this way makes it possible to form its lexicographic database in automatic mode. This stage will be considered in a separate paper.

3. Discussion

After going through a number of stages, we have achieved many benefits:

1. In the digital world, dictionaries will be given new life as they are presented in a modern way.
2. Working with the content showed many errors that the program highlighted.
3. In the future proper XML will help implement the right search engine on site.
4. Any changes that will need to be made to the site can be made through a modern editing system.

4. Conclusion

Although there are still questions, it has been demonstrated that it is possible to digitize a paper dictionary and save it in XML and on the Internet. The key is to use standard components that can be reused in other projects and have simple data formats that are easy to edit with free tools

5. References

- [1] D. M. Grodzinsky, L. O. Simonenko and other. Ukrainian biological terminology Dictionary. – K.: KMM, 2012. – 746 p.
- [2] V. A. Shyrokov Computer lexicography: Monograph / Palagin O.V.; Ukrainian Lingua-Information Fund – Kyiv. : Nauk. dumka, 2011. – 351 p.
- [3] V. A. Shyrokov etc. Linguistic and information studies: works of the Ukrainian Language and Information Fund NAS of Ukraine: y 5 V. V. 1 : Scientific paradigm and basic language and information structures. Kyiv. Ukrainian Lingua-Information Fund of NAS of Ukraine. 2018. 271 p. URL: https://movozaivstvo.org.ua/files/tom_1_B5_print.pdf. doi: 10.33190/978-966-02-8683-2/8684-9.
- [4] V. A. Shyrokov etc. Linguistic and information studies: works of the Ukrainian Language and Information Fund NAS of Ukraine: in 5 V. V. 2 : Grammar systems. Kyiv. Ukrainian Lingua-Information Fund of NAS of Ukraine. 2018. 300 p.
- [5] V. A. Shyrokov etc. Linguistic and information studies: works of the Ukrainian Language and Information Fund NAS of Ukraine: in 5 V. V. 5 : Virtualization of linguistic technologies. Kyiv. Ukrainian Lingua-Information Fund of NAS of Ukraine. 2018. 239 p. URL: https://movozaivstvo.org.ua/files/Ling_inf_studio_TOM_5_umif_B5.pdf. doi: 10.33190/978-966-02-8683-2/8690-0
- [6] V. A. Shyrokov Grammatical systems: phenomenological approach / V. A. Shyrokov, T. P. Lyubchenko, I. V. Shevchenko, K. V. Shyrokov. – K. : Nauk. dumka, 2018. – 310 p.
- [7] O. Karpova Lexicography and Terminology: A Worldwide Outlook / Olga Karpova, Faina Kartashkova. – Cambridge : Cambridge Scholars Publishing, 2009. – 205 p.
- [8] I. Kernerman A multilingual trilogy: Developing three multi-language lexicographic datasets. Electronic Lexicography in the 21st Century: Linking lexical data in the digital age. Proceedings of eLex 2015, 11-13 August 2015. – 372-383p. URL: <https://elex.link/elex2015/>