

КОРПУС КАО ОРУЂЕ ЗА ПРОНИЦАЊЕ ТАЈНИ МЕЂУЈЕЗИКА

(International Corpus of Learner English:

<https://corpora.uclouvain.be/cecl/icle/home>; Sylviane Granger, Maïté

Dupont, Fanny Meunier, Hubert Naets, Magali Paquot (Eds.).

International Corpus of Learner English. Version 3. Louvain-La-Neuve,
Belgium: Presses universitaires de Louvain, 2020, 259 pp.)

Већ дуже од пола вијека корпусна лингвистика представља изузетно живу област лингвистичких истраживања. Разнолики електронски корпуси, који наглу експанзију доживљавају захваљујући развоју модерних информационих технологија, пружају могућност квалитативних и квантитативних истраживања обиља језичких феномена, коришћењем трансверзалних и/или (псеудо)лонгитудиналних метода. Шездесетих година прошлог вијека настају први корпуси писаног и говорног енглеског језика. Касније долази до формирања мноштва других и другачијих корпуса, како на енглеском тако и на осталим језицима. Временом постаје јасан значај корпуса и корпусне лингвистике у настави и учењу страних језика, те се јавља потреба за успостављањем ученичких корпуса, тј. корпуса писмене и усмене продукције неизворних говорника на страном језику. Тиме постаје могуће проучавање комплексне природе међујезика, те међујезичког и унутарјезичког утицаја (односно трансфера у учењу страних језика) и сличних појава. Управо такав је и корпус *ICLEv3*¹ (енг. *International Corpus of Learner English – Version 3*), који ћемо, кроз пратећу публикацију наведену у парентези наслова и платформу на којој функционише, представити у овом приказу.

Како се и из самог назива може претпоставити, ради се о трећој верзији овог корпуса². Прва и друга верзија комплетиране су 2002, односно 2009, а чинили су их аргументативни састави на енглеском

¹ Корпус *ICLEv3* доступан је на сљедећој веб-адреси: <https://corpora.uclouvain.be/cecl/icle/home>.

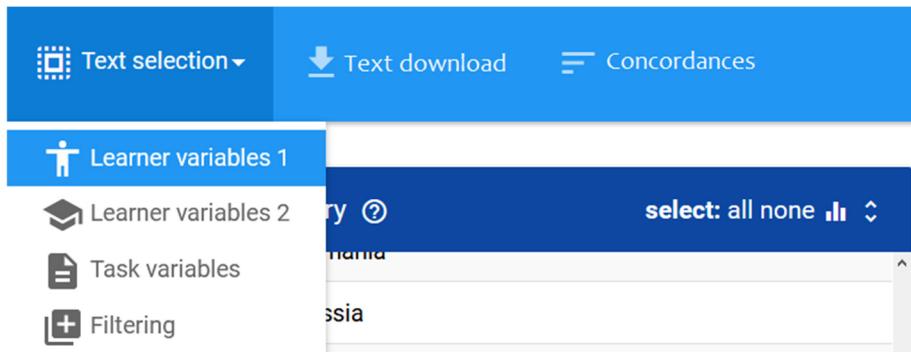
² 1995. године белгијски Центар за англистичку корпусну лингвистику започиње развој корпуса усмене продукције неизворних говорника енглеског језика (*LINDSEI – Louvain International Database of Spoken English Interlanguage*). Касније је формиран и референтни корпус усмене продукције изворних говорника енглеског језика (*LOCNEC – Louvain Corpus of Native English Conversation*).

чији су аутори неизворни говорници на напредном нивоу учења енглеског језика. У том периоду прикупљени су састави изворних говорника бугарског, кинеског, чешког, холандског, финског, француског, њемачког, италијанског, јапанског, норвешког, пољског, руског, шпанског, шведског, цванског и турског језика. Прва верзија корпуса, као резултат пројекта који је, на Католичком универзитету у Левену (фр. *Université catholique de Louvain*) у Белгији, још 1990. године покренула Силвијана Грејнџер [Sylvianne Granger], састојала се од 2,5 милиона ријечи, прикупљених из аргументативних састава изворних говорника 11 различитих језика. Друга верзија представљала је значајан помак у односу на прву, како у броју прикупљених ријечи (3,7 милиона) тако и у броју различитих материјних језика ученика (16). Трећа верзија корпуса (*ICLEv3*), доступна јавности од јануара 2020, представља кулминацију дугогодишњег рада белгијског Центра за англистичку корпуслу лингвистику (енг. *CECL – Centre for English Corpus Linguistics*) и значајна је из два разлога: 1) броји рекордних 5,5 милиона ријечи, а број различитих материјних језика повећан је на 25 (од нових језика, ту су бразилски португалски, грчки, мађарски, персијски [Иран], корејски, литвански, македонски и пакистански, а значај за наше говорно подручје огледа се у томе што ова верзија први пут садржи и српску компоненту – *ICLE-SE*) и 2) корпус је доступан на потпуно новој интернетској платформи, која се одликује флексибилношћу у погледу лакоће и интуитивности претраживања самог корпуса, као и могућностима проширивања корпуса поткорпусима који накнадно буду комплетирани. И трећа верзија, као и претходне двије, врло је хомогена, пошто су сви тимови задужени за прикупљање корпуса усвојили исте смјернице у погледу: врсте састава који се пишу, нивоа познавања енглеског језика ученика и прављења разлике између енглеског језика као страног, односно другог језика.

Трећу верзију корпуса прати и публикација *International Corpus of Learner English. Version 3*, објављена 2020. од стране Католичког универзитета у Левену (*Louvain-la-Neuve*). Ова публикација броји 277 страница, а састоји се од пет поглавља и четири прилога. Прво поглавље (3–22), које слиједи након увода, садржи опис корпуса, критеријуме који су примијењени приликом његовог скупљања, ученичке варијабле, типове задатака чијој су изради ученици приступили, означавање и језичку анотацију. У другом поглављу (23–33) представљени су тимови који су учествовали у прикупљању и формирању корпуса, и то: координациони тим, тим информатичких стручњака, те национални тимови. Треће поглавље (23–33) садржи опис претходно споменутих 25 националних поткорпуса. Четврто

поглавље (53–83) представља свеобухватан приручник за коришћење саме платформе *ICLEv3*. Пето, завршно и најдуже поглавље (83–236), састоји се од 25 појединачних извјештаја³ различитог обима о положају енглеског језика, сачињених од стране националних тимова. Ти извјештаји, између остalog, садрже информације о језичкој ситуацији и политици учења енглеског и других страних језика у основном, средњем и високом образовању, те приступима у учењу енглеског језика и пратећим трендовима у земљама из којих национални тимови потичу. Прилоге чине: 1) списак кодова додијељених високошколским установама које су учествовале у прикупљању националних поткорпуса, 2) списак предложених тема за писање аргументативних састава, 3) списак вишечланих јединица и 4) списак ознака помоћу којих је могуће вршити претрагу.

У наставку ћемо представити платформу на којој је ова верзија корпуса заснована. Како би се корпус могао претраживати, најприје је неопходно извршити одабир текстова на основу мноштва понуђених параметара.



Слика 1. Одабир текстова (енг. *Text selection*)

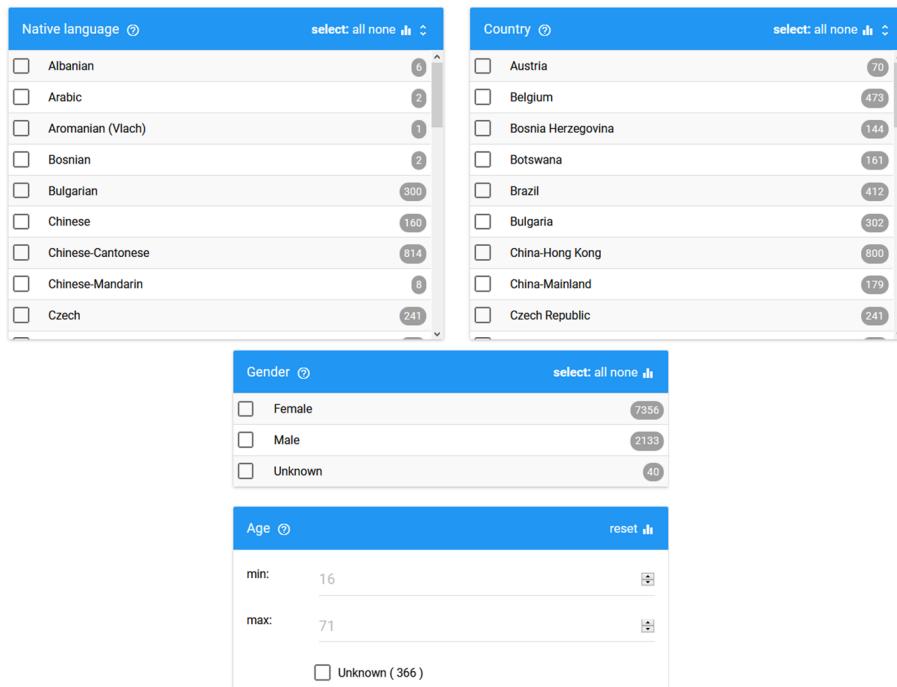
Исправа су доступна три падајућа менија: 1. *Text selection* (нуди читав низ варијабли за одабир текстова, и то: *Learner variables 1*, где се могу одабрати материјни језик, земља из које студенти долазе, пол, узраст, страни језици које познају, те језици који се користе код куће, затим *Learner variables 2*, где се бира образовна институција коју студенти похађају, те *Task variable*, где су понуђени аргументативни, литеарни и остали састави, услови у којима је састав писан, тј. да ли је

³ Извјештај о положају енглеског језика у Републици Србији и Републици Српској сачинили су проф. др Ненад Томовић и проф. др Јелена Марковић.

израда била временски (не)ограничена, као и да ли је састав настao у оквиру (пред)испитних обавеза, те да ли су коришћени неки извори, као и могућност груписања текстова на основу осталих претходно описаних параметара); 2. *Text download* (служи за преузимање одабраних текстова) и 3. *Concordances* (служи за претраживање конкорданција).

За потребе овог приказа бирамо цјелокупан корпус, тј. 9,529 аргументативних састава који броје преко 5,5 милиона ријечи.

selected texts: 9529 (5,766,522 words)



Слика 2. Ученничке варијабле 1 (енг. *Learner variables 1*)

У тзв. поједностављеном претраживању конкорданци (енг. *Simple search*) затим дајемо упит за облик који се може очекивати у међујезику неких неизворних говорника – **advices*, како бисмо пројерили његово присуство у одабраном корпусу.

The screenshot shows the 'Simple search' tab selected. In the search bar, the query '*advices' is entered. Below the search bar, there are download options for 'CONCORDANCE IN .XLSX' and 'CSV'. The results section displays 26 hits, each with a document ID and a snippet of text containing the word 'advices'. The snippets are as follows:

- > 1 BGSU1129 From one side is the simple matter of theory and studied **advices** and learned
- > 2 BGSU1129 Graduates are always challenged to making deep observations and taking out the most essential **advices**.
- > 3 BRMG1138 In addition , some **advices** for you to pi
- > 4 BRMG1180 I 'm not saying that people repel their **advices** and the con
- > 5 CNUK2006 During doing this , they do not just listen to their parents **advices** , they also c
- > 6 CZUN1021 Why should n't gardeners watch their favourite programme full of clever **advices** and innovat

Слика 3. Поједностављена претрага конкорданци (енг. *Simple search*) за упит **advices*

Претрага за упит **advices* даје 26 резултата издвојених из састава изворних говорника бугарског, португалског, кинеског, чешког, холандског, француског, грчког, иранског, италијанског, јапанског, корејског, македонског, српског, шпанског и цванског језика.

У наставку, на целиокупном узорку *ICLEv3* вршимо упит на основу облика који је уочен у усменој и писменој продукцији неких студената кинеског и енглеског језика, који су изворни говорници српског, и то: **no any*.

The screenshot shows the 'Simple search' tab selected. In the search bar, the query '*no any' is entered. Below the search bar, there are download options for 'CONCORDANCE IN .XLSX' and 'CSV'. The results section displays 17 hits, each with a document ID and a snippet of text containing the phrase 'no any'. The snippets are as follows:

- > 1 BGSU1196 There is **no any** other reasonable explanation why an experienced teacher would give up his , otherwise noble , profession
- > 2 CNRK1172 There is **no any** good effect to our economy .
- > 3 CNRK1585 and administrators and managerial personals , but **no any** low-skilled workers such as physical labour workers .
- > 4 CNRK1726 Ocean Park have **no any** accommodation facilities .
- > 5 CNRK1772 There is **no any** benefit to either teenagers or children .
- > 6 CNUK1072 written by the schooler who have **no any** real practice or experience of the subject they are talking .
- > 7 CNUK4010 We have **no any** right to decide what kind of people it will be .
- > 8 IRMA05002 There is **no any** doubt about it that , prison is a dangerous place , especially for those who enter
- > 9 KRBF1058 the same school even though there are **no any** solid evidence for that .
- > 10 KRHY1046 watch tv after their daily routine , there is **no any** conversation or heat .

Слика 4. Поједностављена претрага конкорданци за упит **no any*

Претрага даје 17 резултата издвојених из састава изворних говорника бугарског, кинеског, корејског, иранског, литванског, пакистанског, руског и турског. Овакав корпус, дакле, даје могућност примјене напредних модела изучавања трансфера у учењу страних језика, који подразумијевају вишеструко поређење међујезика изворних говорника различитих језика (а могуће је поређење и с контролним корпусом аргументативних састава изворних говорника британске и америчке варијанте енглеског језика – *LOCNESS – The Louvain Corpus of Native English Essays*, који броји 323 хиљаде ријечи), као и све типове усмјерености трансфера, тј. комплексног узајамног утицаја свих језика које неки ученик познаје.

У наставку ћемо описати и могућности напредне претраге корпуса (енг. *Advanced search*), те на цјелокупном корпусу *ICLEv3* приказати начин на који упити функционишу.

The screenshot shows the 'Advanced search' interface for the ICLEv3 corpus. At the top, there are two tabs: 'Simple search' (disabled) and 'Advanced search' (selected). Below the tabs are several search fields and operators:

- Form (case insensitive) equals Form (case insensitive)
- Form (case sensitive) equals Form (case sensitive)
- Lemma equals Lemma
- Part of speech equals Part of speech
- Simplified Part of speech equals Simplified part of speech
- Any word

At the bottom, there are buttons for navigating between search terms: 'MOVE TO THE LEFT' and 'MOVE TO THE RIGHT', and buttons for managing the query: 'DELETE THIS WORD', 'DELETE THE QUERY', and 'SEARCH'.

Слика 5. Напредна претрага (енг. *Advanced search*)

Напредна претрага корпуса нуди могућност задавања шест различитих типова упита, почевши од: 1) претраге било ког облика ријечи, независно од тога да ли садржи велика слова (*Form: case insensitive*), као и 2) претраге која издваја ријечи које не садрже велика слова (*Form: case sensitive*), затим 3) претраге по лемама (*Lemma*), односно свих могућих облика неке леме (тако се нпр. претрагом помоћног глагола *do* добијају и резултати који, поред самог глагола који се претражује, садрже и облике *does, doesn't, did, didn't, done, doing*). Могућа је и 4) претрага помоћу врсте ријечи (*Part of Speech*) (засно-

вана на детаљном скупу етикета које предвиђа CLAWS⁴, попут: упитних детерминатора *DDQ* (*wh-determiner*), приједлога (*IF – preposition for, IO – preposition of*), затим вишечланих приједлога (*II21, II22, II31*), заједничких именица (*NN – common noun*), разних типова сложеница (*NN121, NN132, NN141*), глагола (*VB0 – be, VDD – did, VH2 – has, VV0 – lexical verb base form, VVD – lexical verb past tense*), прилога (*RR – general adverb*), пријевра (*JJR – general comparative adjective*), итд. Доступна је и 5) претрага помоћу поједностављених етикета за врсте ријечи (*Simplified Part of Speech*), такође заснованих на CLAWS7, попут *ADJ* (пријеври), *ADV* (прилоги), *DET* (детерминатори), *N* (именице), *NEG* (одрични облици), *PREP* (приједлози), *GE* (генитиви), итд. Поред свих наведених типова претраге, могуће је вршити и 6) претрагу по „било којој ријечи“ (*any word*), где је астериск (*) ознака за такву ријеч. На тај начин могуће је у низовима узастопних ријечи посматрати једну позицију означену астериском, која је промјенљива. Тако претрага упитом *on the (*) hand* даје и резултат *on the one hand*, као и *on the other hand*. Сваки од описаних типова упита нуди могућност одабира да ли издвојени резултати почину траженом ријечју, завршавају њом, или је садрже и сл., те извоза резултата у документе формата *.XLSX* и *.CSV*.

Даље вршимо претрагу именице *courage* помоћу првог и трећег типа упита, те по једног типа лексичких (*V+N*) и граматичких колокација (*Adj+Prep*), заснованих на поједностављеним етикетама за врсте ријечи.

The screenshot shows the CLAWS7 search interface with the query '(form_c:c courage)' entered. It displays 141 hits. The results are listed in a table with columns for hit number, ID, and text snippet. The first few hits are:

>	1 BG001146	Their dreams however remain on the subway because they did n't have the courage to get off .
>	2 BG001276	people grow up free of that ancient prejudice - a fact that gives them courage .
>	3 BG001739	all other creatures on the Earth , are not the same in strength , courage , goodness and even thoughts .
>	4 BR0001156	be a revolutionary , and not everybody is built with the strength or the courage to take on the world .

Слика 6. Напредна претрага помоћу првог типа упита, за именицу *courage*

Претрага именице *courage* извршена на цијелом корпусу *ICLEv3* даје 141 резултат.

⁴ <http://ucrel.lancs.ac.uk/claws7tags.html>.

Уколико обавимо трећи тип упита, тј. извршимо претрагу по лемама, добијамо и садашње и прошле партиципе ових глагола и перфекатске облике (*discouraging, encouraged*), као и именице (*discouragement* и *encouragement*).

The screenshot shows a list of 23 search results from a corpus. Each result includes a snippet of text and a link to the full document. The results are as follows:

- > 14 [BOSN1083] By **encouraging** them to think critically, organise and express their thoughts orally or in written form,
- > 15 [BOSN1098] They **encourage** and win the student's interest thus facilitating the educational process.
- > 16 [BOSN1146] Their dreams however remain on the subway because they did n't have the **courage** to get off .
- > 17 [BOSN1148] cycle functions perfectly in our century The modern scientific , technical and industrial development **encourages** us to dream and strive to have our dreams fulfilled (in simulative or real ways
- > 18 [BOSN1149] And this might be much **discouraging** .
- > 19 [BOSN1195] Nonetheless , it should be **encouraged** adequately by the government - for instance , by tax concession for the firms which steadily
- > 20 [BOSN1207] of higher learning where the brightest were brought together in an environment that would **encourage** wild ideas , creativity , debate and in the process expand the horizons of basic science
- > 21 [BOSN1207] who study and work ? " said , " We can neither forbid nor **encourage** them to do that but statistics show that students who have been working during these 4
- > 22 [BOSN1214] The idea of teamwork may be **encouraged** in theory , but in practice , teamwork , if it exists , is usually optional
- > 23 [BOSN1214] Furthermore , the absence of practical skills has to do with **discouragement** of students ' expressing personal opinion , which inevitably leads to suppression of lead

Слика 7. Напредна претрага помоћу трећег типа упита, за лему *courage*

Оваквим претрагама корпуса, примјеном разних доступних параметара, могуће је вршити поређења, као и квалитативна и/или квантитативна истраживања чији је предмет међујезик изворних говорника једног или групе разних матерњих језика, те разни творбени процеси и сл.

На kraју, помоћу поједностављених етикета за врсте ријечи извршимо претрагу претходно споменутих типова лексичких (*V+N*) и граматичких колокација (*Adj+Prep*). Из целокупног корпуса издвојено је 66,619 примјера који садрже овај тип лексичких колокација *V+N*.

The screenshot shows a list of 4 search results for the V+N collocation type. Each result includes a snippet of text and a link to the full document. The results are as follows:

- > 1 [BOSN1001] of a country is based on its enormous industrial corporations that are gradually **replacing men** with machines .
- > 2 [BOSN1001] But I think that in our modern world which **worships science** and technology there is still a place for dreams and imagination .
- > 3 [BOSN1001] Besides they still **create literature** which means they are still capable of creating new imaginary worlds .
- > 4 [BOSN1001] People still use their imagination to **paint pictures** and to compose music .

Слика 8. Напредна претрага помоћу поједностављених етикета за упит *V+N*

Но, важно је истаћи да је у резултатима претраге уочен и извјестан број колокација које садрже прошле партиципе у улози атрибута. Стога је претходно описана сложенија и свеобухватнија претрага помоћу етикета за врсте ријечи (упитима попут *VV0+NN*, *VVD+NN* и сл.) пожељна како би из резултата претраге аутоматски били искључени такви примјери.

Претрагом типа граматичких колокација *Adj+Prep* добијамо 33,021 примјер.

The screenshot shows a search interface for a corpus. At the top, there are two buttons: '(прос~ *ADJ)' and '(прос~ PREP\$)'. Below them, it says 'Results: 30021 hit(s)'. There are two download options: 'DOWNLOAD CONCORDANCE IN XLSX (MAXIMUM: 10,000 HITS)' and 'DOWNLOAD CONCORDANCE IN CSV (MAXIMUM: 10,000 HITS)'. On the right side, there are navigation buttons for the search results, including arrows and a search icon. The results are listed in a table with four rows:

Line Number	Hit ID	Text Excerpt
> 1	BGDU1001	Besides they still create literature which means they are still capable of creating new imaginary worlds .
> 2	BGDU1002	Computers are becoming more and more important in our life and today every educated person is expected to be able to work with computers
> 3	BGDU1002	The lectures we had were quite useless for people with no technical education and instead of trying to memorize incomprehensible data we could have
> 4	BGDU1003	It is not only in affluent societies that people are obsessed with the idea of making more money .

Слика 9. Напредна претрага помоћу поједностављених етикета за упит *Adj+Prep*

И оваквим типом упита, као и претходно описаним, могуће је вршити разне облике поређења међујезика изворних говорника различитих матерњих језика, као и поређења с контролним корпусом који смо споменули, те другим, значајно обимнијим корпусима енглеског језика изворних говорника (попут *BNC – British National Corpus* и *COCA – Corpus of Contemporary American English*).

Приручник за *ICLEv3* (доступан у електронској форми на слеђећој веб-адреси: https://corpora.uclouvain.be/cecl/icle/ICLEv3_manual_100371-PUL-ICLEv3-V3_final.pdf), под називом *International Corpus of Learner English – Version 3*, чији су уредници Силвијана Грејнцер, Маите Дјупонт [Maïté Dupont], Фани Муније [Fanny Meunier], Хуберт Нетс [Hubert Naets] и Магали Пако [Magali Paquot] 2020. године издала је универзитетска штампарија Универзитета у Левену, Белгија (*Presses universitaires de Louvain: Louvain-La-Neuve, Belgium*).

Српска компонента треће верзије корпуса (*ICLE-SE*), на иницијативу проф. др Јелене Марковић, прикупљена је у периоду од септембра 2015. до јуна 2016. године. Тим који је радио на прикупљању српске компоненте, поред руководиоца проф. др. Јелене Марковић, чинила су три стручњака из области англистичке лингвистике: проф. др Ненад Томовић (Универзитет у Београду), проф. др Биљана Радић Бојанић (Универзитет у Новом Саду), проф. др Жељка Бабић (Универзитет у Бањој Луци), те три млада истраживача/сарадника: Миња Радоња (Универзитет у Источном Сарајеву), Јелена Матић (Универзитет у Београду) и Срђан Шућур (Универзитет у Источном Сарајеву). Српски поткорпус чини 202,621 ријеч, издвојена из 325 аргументативних састава на енглеском студената катедри за англистику на два универзитета у Републици Српској: Катедре за англистику Филозофског факултета у Источном Сарајеву и Катедре за англистику Филолошког факултета у Бањој Луци, као и студената катедри за англистику два универзитета у Србији: Катедре за англистику Филолошког

факултета Универзитета у Београду и Катедре за англистику Филолошког факултета Универзитета у Новом Саду (од чега су из Источног Сарајева – 75 састава, 48,932 ријечи, Бања Луке – 73 састава, 50,959 ријечи, Београда – 100 састава, 59,437 ријечи и Новог Сада – 77 састава, 43,293 ријечи).

Корпус *ICLEv3* и његова српска компонента *ICLE-SE* послужили су и служе као основа за научно-истраживачке пројекте, те за израду монографија, дисертација и научних радова⁵ из разних области англистичке лингвистике.

Корпус функционише на платформи *Corpor@⁶*, осмишљеној од стране Центра за обраду природног језика (фр. *Centre de Traitement Automatique du Langage – CENTAL*). Ова платформа омогућиће проширивање корпуса свим будућим корпусима који накнадно буду прикупљени у сарадњи са белгијским Центром за англистичку корпушну лингвистику. Како активности Центра трају пуних тридесет година,

⁵ Gries, S. & Wulff, S. (2020). Examining individual variation in learner production data: A few programmatic pointers for corpus-based analyses using the example of adverbial clause ordering. *Applied Psycholinguistics*, 1-21, 279–299. doi:<https://doi.org/10.1017/S014271642000048X>

Марковић, Ј. (2020). Концесивни конектори *though* и *however* у писању на енглеском језику код изворних и неизворних говорника. *Филолој – часопис за језик, књижевност и културу*, 21, 13–35. doi:<http://doi.org/10.21618/fil2021013m>

Radić-Bojanić, B. (2019). Neodređena zamenica ONE u pisanju kod neizvornih govornika engleskog jezika. *Godišnjak Filozofskog fakulteta u Novom Sadu*, 44 (2), 39–52. doi:<https://doi.org/10.19090/gff.2019.2.39-52>

Radonja, M. (2020). The use of interactive metadiscourse in Serbian students' writing in English. *Радови Филозофској факултети*, 21(2), 121–134. doi:<https://doi.org/10.7251/FIN1921121R>

Römer, U. et al. (2018). Verb-argument constructions in advanced English learner production: Insights from corpora and verbal fluency tasks. *Corpus Linguistics and Linguistic Theory*, 16(2), 303–331. doi:<https://doi.org/10.1515/cllt-2016-0055>

Schweinberger, M. (2020). How Learner Corpus Research can inform Language Learning and teaching – An analysis of adjective amplification among L1 and L2 English speakers. *Australian Review of Applied Linguistics*, 43 (2), 196–218. doi:<https://doi.org/10.1075/aral.00032.sch>

Šućur, S. (2019). Distribucija frazalnih glagola u pisanju na engleskom kao stranom kod srbofonih говорника. *Komunikacija i kultura online*, 10, 120–143. doi:<https://doi.org/10.18485/kkonline.2019.10.10.7>

⁶ <https://corpora.uclouvain.be/catalog/>.

уз доступност све три верзије корпуса, отвара се мноштво могућности за вршење истраживања, нпр. међујезичке дијахроније⁷ и поређења с еволуцијом енглеског језика као извornog, те процеса попут амери-канизације на плану лексике и сл.

Срђан Р. Шућур
Универзитет у Источном Сарајеву
Филозофски факултет
srdjan.sucur@ffuis.edu.ba

⁷ Gilquin, G. (2019). Diachronic learner corpus research: Examining learner language through the lens of time. *International Computer Archive of Modern and Medieval English Conference, ICAME 40*. <http://hdl.handle.net/2078.1/217739>