

CLARIN

Vienota valodas resursu un tehnoloģiju infrastruktūra

Inguna Skadiņa
CLARIN-LV nacionālā koordinatore

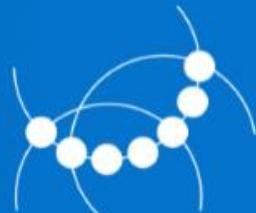


Latvijas Universitātes
Matemātikas un informātikas institūts

Zinātnieku brokastis
RSU

2023. gada 6. decembrī

CLARIN



Vienota valodas resursu un tehnoloģiju infrastruktūra

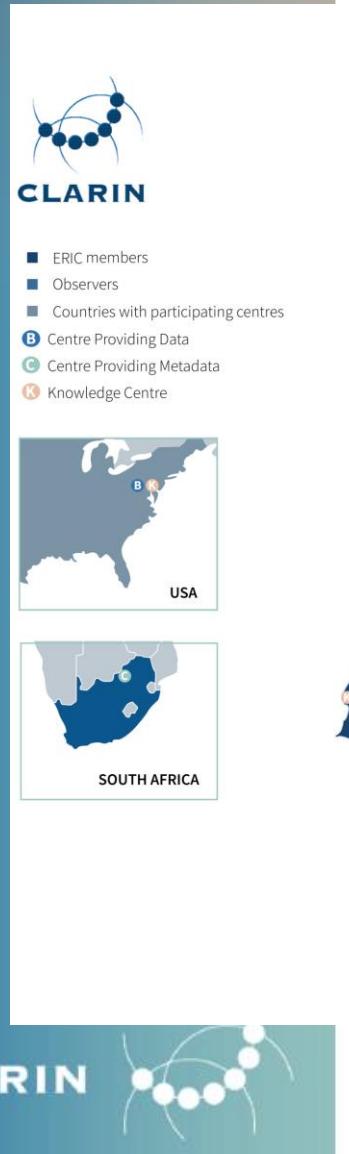
CLARIN (Common Language Resources and Technology Infrastructure) ir digitāla Eiropas pētniecības infrastruktūra (ERIC)

Tās pamatā ir ideja, ka

visi digitālie valodas resursi un rīki Eiropā un citur pasaulē ir pieejami

visu jomu, it īpaši humanitāro un sociālo zinātņu zinātniekiem un studentiem, izmantojot vienotu pierakstīšanos.

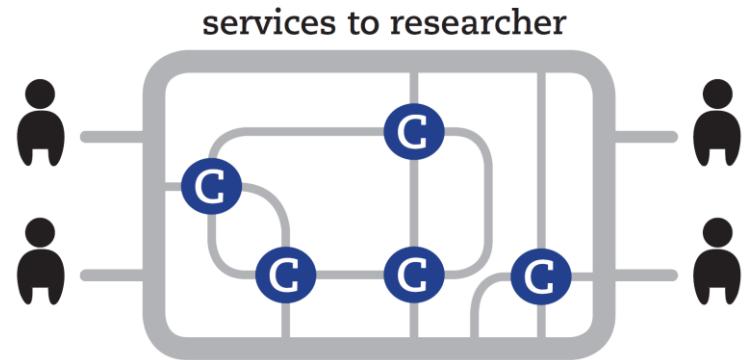
CLARIN – dalīta Eiropas pētniecības infrastruktūra



- 23 + 3 valstis
- > 60 reģistrētu centru
- Zināšanu centru tīkls (K-centri)
- Vienkārša un **ilgtspējīga** piekļuve digitālajiem valodas datiem
- Mūsdienīgi valodas apstrādes rīki, valodas datu izpētītei un analīzei neatkarīgi no to atrašanās vietas
- Cieša sasaiste ar Atvērtās zinātnes programmu, fokuss uz **sadarbspēju**

FAIR principles for open language resources

- **F – *findability*:**
existence at a data **provider**, discovery, **persistence**, long-term **preservation**
- **A – *accessibility*:**
open data / access
- **I – *interoperability*:**
common **terminology**, data **models** and **formats** (for both humans & machines)
- **R – *reusability*:**
content, **documentation**, provenance, **versioning**, licencing



Par CLARIN

CLARIN (Common Language Resources and Technology Infrastructure – Vienota valodas resursu un tehnoloģiju infrastruktūra) ir dalīta Eiropas pētniecības infrastruktūra (ERIC), kurā integrētas zināšanas, valodas resursi un rīki, repositoriji un servisi, ko piedāvā daudzie CLARIN centri un nacionālie konsorcijs.

CLARIN mērķis ir novērst sadrumstalotību valodas resursu jomā un padarīt valodas resursus pieejamus visu jomu, it īpaši humanitāro un sociālo zinātņu zinātniekiem un studentiem. Lai to īstenotu, izveidota kopīga izkliedēta infrastruktūra, kurā integrēti valodas resursi un rīki no visas Eiropas. CLARIN piedāvā ilgtermiņa risinājumus un servisus digitālo valodas datu un rīku izvietošanai, savienošanai un analīzei.

Latvija CLARIN iniciatīvā piedalās kopš tās pirmsākumiem. 2008. gadā LU MII kļūst par CLARIN sagatavošanas posma projekta konsorcija dalībnieku, būtisku finansiālu atbalstu dalībai projektā sniedz Izglītības un zinātnes ministrija. 2016. gada 1. jūnijā Latvija pievienojas CLARIN ERIC. Izglītības un zinātnes ministrija uzticējusi LU Matemātikas un informātikas institūtam pārstāvēt Latviju CLARIN ERIC un vadīt Latvijas CLARIN konsorciju. 2019. gadā CLARIN-LV pievienojas CLARIN zināšanu centram morfoloģiski bagātām valodām SAFMORIL. 2020. gada martā tiek izveidots CLARIN-LV repositorijs, kurā tiek reģistrēti latviešu valodas resursi un rīki. Esot CLARIN ERIC konsorcijā, CLARIN-LV ir apņēmusies ilgstoši rūpēties un saglabāt repositorijā deponētos digitālos valodas resursus un rīkus. CLARIN-LV īsteno CLARIN ERIC misiju Latvijā, vācot, dokumentējot, kurējot un nodrošinot ilgtermiņa piekļuvi digitālajiem latviešu valodas resursiem un rīkiem. 2022. gada janvārī, konsorcijs apvienojoties septiņiem partneriem, tiek noslēgts CLARIN nacionālā konsorcijs līgums, kurā CLARIN-LV konsorcijs vienojas par CLARIN-LV darbību un turpmāku attīstību. 2023. gada janvārī CLARIN-LV repositorijs iegūst B-centra statusu un saņem CoreTrustSeal sertifikātu kā uzticams datu repositorijs.

CLARIN-LV regulāri rīko konferences un seminārus, kuros iepazīstina ar dažādiem valodas resursiem un rīkiem un to lietojumu pētniecībā un valodu tehnoloģiju izveidē. Latvijā paveiktais apkopots vairākās publikācijās.

Kopš 2018. gada CLARIN Latvija darbību atbalsta ERAF projekts "Latvijas Universitāte un institūti Eiropas pētniecības telpā - ekselēnce, aktivitāte, mobilitāte, kapacitāte", kā arī projekti "Humanitāro zinātņu digitālie resursi: integrācija un attīstība" (5.10.2020-5.10.2022), "Atvērtas un FAIR principiem atbilstīgas digitālo humanitāro zinātņu ekosistēmas attīstība Latvijā" (kopš 2022. gada decembra), "Mūsdienu latviešu valodas izpēte un valodas tehnoloģiju attīstība" (kopš 2022. gada) un "Valodu tehnoloģiju iniciatīva" (kopš 2023. gada).



CLARIN-LV piedalās ikgadēja CLARIN konferencē

No 16. oktobra līdz 19. oktobrim Lēvenē notika gadskārtējā Eiropas pētniecības infrastrūtūras CLARIN konference.



www.clarin.lv
info@clarin.lv

CLARIN-LV valodas resursu repositoījs

Repositorijs

Meklēšana korpusā

Par vietni



Atrast



Lingvistiskie dati un valodas apstrādes rīki

Citēšanas atbalsts (ar pastāvīgajiem ID)



Meklēt

Detalizētā meklēšana

Autors

Grūzītis, Normunds (21)

Darģis, Roberts (20)

Saulīte, Baiba (15)

Pretkalniņa, Lauma (13)

Rituma, Laura (12)

... Skatīt vairāk

Temats

text (17)

morphology (14)

dictionary (12)

manual annotation (8)

constituency (7)

... Skatīt vairāk

Valoda (ISO)

Latvian (58)

English (5)

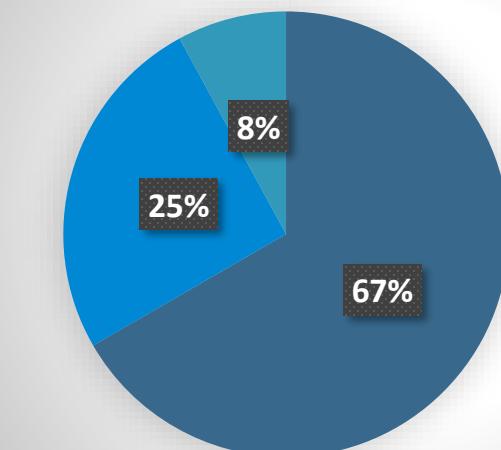
German (4)

Lithuanian (4)

Latgalian (3)

... Skatīt vairāk

Valodas resursi un rīki



- Korpusi
- Leksikoni
- Rīki

CLARIN-LV valodas resursu repositorijs

Kas jauns

LexicalConceptualResource

CLARIN Centre Of Latvian Language Resources And Tools

Dictionary of Contemporary Latvian Language (MLVV) (2023-09-21)



Autors (-i):

Jērāne, Santa ; et al.

► show everyone

Apraksts:

"Contemporary dictionary of Latvian language" (MLVV), which is developed by the UL Latvian Language institute, is a new explanatory dictionary based on Latvian language materials obtained during the last decade. The analysis ...

► Šajā vienām ir 1 failis (7.05 MB).

Publicly Available

Corpus

CLARIN Centre Of Latvian Language Resources And Tools



Corpus of Latvian PhD Theses (Disertācijas)

Autors (-i):

Dargis, Roberts

Apraksts:

The corpus consists of PhD theses and abstracts published in the University of Latvia, Riga Technical University, Riga Stradiņš University and Liepaja University until 2020.

► Šajā vienām ir 3 faili (127.73 MB).

Publicly Available

CLARIN-LV valodas resursu rezervuārs

Corpus

LVMED: Latvian Speech Transcripts of the Medical Domain
(AiLab IMCS UL / 2021-09-30)

Autors (-i):
Auziņa, Ilze ; et al.
▶ show everyone

Šajā vienā ir 1 fails (267.18 KB).

CLARIN Centre Of Latvian Language Resources And Tools

Publicly Available

SINGLE-WORDS ✓ MULTI-WORDS ✓

reference corpus: Saeima

Word	Word	Word	Word	Word
1 plauša	11 CT	21 patoloģisks	31 pleira	41 perēklis
2 limfmezgls	12 urīnpūslis	22 žultspūslis	32 dobums	42 iekava
3 akna	13 virsniere	23 daiva	33 mililitrs	43 sieniņa
4 centimetrs	14 liesa	24 gluds	34 kontrastēt	44 aksiāls
5 homogēns	15 dziedzeris	25 izmeklējums	35 ieslēgums	45 žultsvads

CLARIN-LV valodas resursu rezervuārs

Corpus

LVMED: Latvian Speech Transcripts of the Medical Domain
(AiLab IMCS UL / 2021-09-30)

Autors (-i):
Auziņa, Ilze ; et al.
► show everyone

Šajā vienumā ir 1 fails (267.18 KB).

CLARIN Centre Of Latvian Language Resources And Tools

Publicly Available

23	<input type="checkbox"/>	(i) doc#89	svaigu infiltrāciju neredz . </s><s> pneimofibroze. </s><s>	sirds	palielināta pa kreisi, aorta vecuma robežā . </s><s> trahejā
24	<input type="checkbox"/>	(i) doc#91	sklerozētu sienu. </s><s> un tad secinājumā lūdzu rakstām	sirds	neizvērtējama punkts </s><s> un tad apr* secinājumā lūdzu
25	<input type="checkbox"/>	(i) doc#94	s> pastiprināts plaušu zīmējums piesakņu rajonā . </s><s>	sirds	, aorta vecuma normā . </s><s> sinus brīvi. </s><s> vēderā
26	<input type="checkbox"/>	(i) doc#103	><s> nākamā rindā lūdzu rakstām nākamajā rindā </s><s>	sirds	paplašināta šķērsizmērā , vairāk pa kreisi. </s><s> vēl atzīn
27	<input type="checkbox"/>	(i) doc#118	<s> aorta nav paplašināta. </s><s> nākamā rindā </s><s>	sirds	nav paplašināta šķērsizmērā . </s><s> un tas arī viss paldie
28	<input type="checkbox"/>	(i) doc#134	><s> saknes sabiezētas , salīdzinoši kreisā sakne. </s><s>	sirds	palielināta pa kreisi, aorta vecuma robežā . </s><s> kontrole
29	<input type="checkbox"/>	(i) doc#138	hiperplastisks etmoidīts un punkts </s><s> plaušu lauki un	sirds	bez redzamas novirzes no normas. </s><s> paraksts </s><s>
30	<input type="checkbox"/>	(i) doc#141	rencējas punkts šķidrumu pleiras telpās nekonstatē punkts	sirds	nav paplašināta šķērsizmērā . </s><s> aorta nav paplašināt
31	<input type="checkbox"/>	(i) doc#145	s> plašu emfizēma. </s><s> difūza pneimofibroze. </s><s>	sirds	nav palielināta. </s><s> aorta plata, sklerozēta. </s><s> vir:
32	<input type="checkbox"/>	(i) doc#154	:glu kalcinācija kreisā pusē. </s><s> tālāk rakstām </s><s>	sirds	šķērsizmērā nav paplašināta. </s><s> aorta sklerotizēta. </:

CLARIN-LV valodas resursu repositoījs

ToolService

CLARIN Centre Of Latvian Language Resources And Tools

RUTA: MED – Dual Workflow Medical Speech Transcription Pipeline and Editor

(AiLab IMCS UL / 2022)

Author(s):
Znotiņš, Artūrs ; Darģis, Roberts ; Grūzītis, Normunds ; Bārzdiņš, Guntis and Goško, Didzis

This item contains no files.

Saglabāt ⏴ 5s B I U x² x₂ ⋮

MR prostatai ar k/v.
Prostata 3,9 x 3,3 x 3,8 cm, tilpums 26,15 cm³.
PSA līmenis nav zināms.
Dziedzera pārejas daļā redzami labdabīgas hiperplāzijas mezgli.
Urīnpūslis gludām sieniņām, bez intralūmenāliem ieslēgumiem.
Patoloģiska lieluma l/m nesaskatu.

Slēdziens
Labdabīga prostatas hiperplāzija.
Pašreiz nav datu par augstas malignitātes tumora audiem prostatā.

0.00s
4.72s
16.41s
36.58s
68.44s
72.16s
75.92s
77.74s
86.06s

00:00:06 / 00:01:32

The screenshot shows a transcription interface for a medical report. At the top, there's a header for 'RUTA: MED – Dual Workflow Medical Speech Transcription Pipeline and Editor' from 'AiLab IMCS UL / 2022'. Below it, author information is listed. A message says 'This item contains no files.' There are several buttons for saving and styling text. The main content area displays a transcribed medical report in Latvian. The report discusses the prostate size (3,9 x 3,3 x 3,8 cm), PSA levels, and prostate gland findings. A section titled 'Slēdziens' (Conclusion) states 'Labdabīga prostatas hiperplāzija.' (Benign prostate hyperplasia). Below the text is a waveform visualization of the speech recording, with a play button and a timestamp '00:00:06 / 00:01:32'.

CLARIN-LV valodas resursu repozitorijss

Kas jauns

LexicalConceptualResource

CLARIN Centre Of Latvian Language Resources And Tools

Dictionary of Contemporary Latvian Language (MLVV) (2023-09-21)



Autors (-i):

Jērāne, Santa ; et al.

► show everyone

Apraksts:

"Contemporary dictionary of Latvian language" (MLVV), which is developed by the UL Latvian Language institute, is a new explanatory dictionary based on Latvian language materials obtained during the last decade. The analysis ...

🔗 Šajā vienām ir 1 failis (7.05 MB).

Publicly Available

Corpus

CLARIN Centre Of Latvian Language Resources And Tools



Corpus of Latvian PhD Theses (Disertācijas)

Autors (-i):

Dargis, Roberts

Apraksts:

The corpus consists of PhD theses and abstracts published in the University of Latvia, Riga Technical University, Riga Stradiņs University and Liepaja University until 2020.

🔗 Šajā vienām ir 3 faili (127.73 MB).

Publicly Available

Dictionary of Contemporary Latvian Language (MLVV) (2023-09-21)

**Author(s):**

Jērāne, Santa ; et al.

[► show everyone](#)**Description:**

"Contemporary dictionary of Latvian language" (MLVV), which is developed by the UL Latvian Language institute, is a new explanatory dictionary based on Latvian language materials obtained during the last decade. The analysis ...

 [This item contains 1 file \(7.05 MB\).](#)**Publicly Available**

This item is **Publicly Available** and licensed under:
Creative Commons - Attribution-ShareAlike 4.0 International (CC BY-SA 4.0)

Name	mlvv_2023_4.tei.zip
Size	7.05 MB
Format	application/zip
Description	MLVV open data in the TEI/XML format (https://tei-c.org/release/doc/tei-p5-doc/en/html/DI.html)
MD5	cef0a6b5399382c98b294b4406c2d77e

 [Download file](#) [Preview](#)

Licences un to pārvaldīšana

ToolService CLARIN Centre Of Latvian Language Resources And Tools

Ilvars - Latvian Male VITS Text-to-Speech Model (vers. 2023)

Autors (-i):
Darģis, Roberts and Auziņa, Ilze

Apraksts:
A neural model for text-to-speech (TTS) synthesis in Latvian. Trained using VITS on a 25-hour speech corpus of audiobooks read in a male voice. Available for academic and non-commercial purposes via an API. To get access ...

 Šajā vienumā ir 1 fails (376.17 MB).

Restricted Use  

Licences un to pārvaldīšana

ToolService

Ilvars - Latvian Male VITS Text-to-Speech Model (vers. 2023)

Autors (-i):
Darģis, Roberts and Auziņa, Ilze

Apraksts:
A neural model for text-to-speech (TTS) synthesis in Latvian. Trained using audiobooks read in a male voice. Available for academic and non-commercial use.

Šajā vienāmā ir 1 fails (376.17 MB).

Licenču pārvaldīšana

All Licenses Define License Define License Label

License Name: CLARIN RESTRICTED

Definition (URL): <https://www.kielipankki.fi/lic/example-license-clarin-res-id-by-cc0>

Confirmation: Ask always

Label: RES

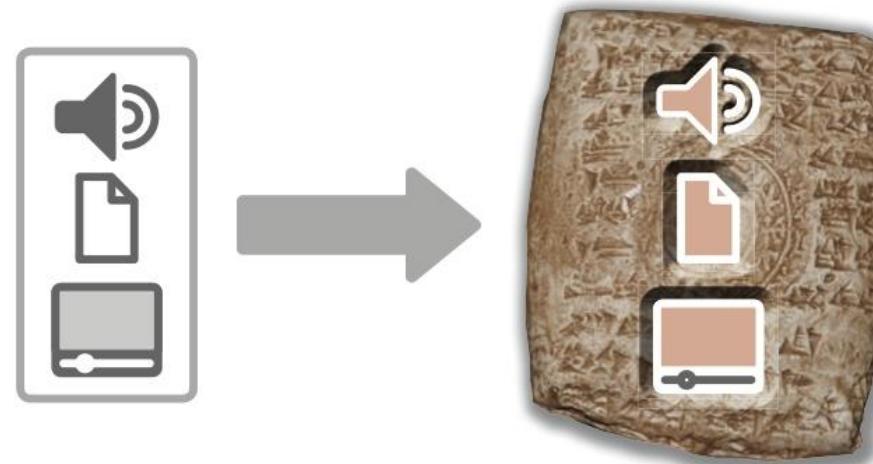
Extended Label(s): BY
SA
NC
ReD
ND

Papildu nepieciešamā lietotāja informācija:

- Lietotājs saņems e-pasta ziņojumu ar lejupielādes instrukcijām.
- Lietotāja vārds
- Dzimšanas datums
- Adrese
- Valsts
- Vaicāt lietotājam citu e-pasta adresi
- Jautāt lietotājam par organizāciju (nav obligāti).
- Jautāt lietotājam par organizāciju (obligāti).
- Pajautājiet lietotājam par viņa nodomiem ar vienumu.

Datu uzglabāšanas servisi: deponēšana

- Viens no CLARIN pamatzdevumiem ir nodrošināt, ka valodas resursi tiek arhivēti, tie ir **pieejami ilgtermiņā** un tie ir **uzticami**
- Tāpēc CLARIN centri piedāvā valodas resursu uzglabāšanas (deponēšanas) pakalpojumu



https://www.clarin.lv/attachments/CLARIN%202020_resursu_iesniegsana.pdf

Ilgspēja

Core Trust Seal and B-centre certification



[Source: [CoreTrustSeal Requirements 2020-22](#)]

CoreTrustSeal self-assessment template

The CoreTrustSeal self-assessment includes 16 requirements (R1–R16) plus R0 providing contextual information on the repository. This template contains all requirements along with guidance for formulating self-assessment statements and gathering related evidence. Along with the self-assessment statements, the applicant must indicate a compliance level for R1–R16:

0. Not applicable
1. The repository has not considered this yet
2. The repository has a theoretical concept
3. The repository is in the implementation phase
4. The guideline has been fully implemented in the repository

The [CoreTrustSeal Trustworthy Data Repositories Requirements: Extended Guidance 2020-2022](#) document contains more information on e.g. missing evidence, understandability, non-English language documentation, sensitive/internal documentation, structure and length of responses, and further guidance for certain requirements. Please read it before starting!



Citēšana un unikālie identifikatori

Universal Dependencies 2.0



Please use the following text to cite this item or export to a predefined format:

BIBTEX

CMDI

Nivre, Joakim; et al., 2017, *Universal Dependencies 2.0*, LINDAT/CLARIAH-CZ digital library at the Institute of Formal and Applied Linguistics (ÚFAL), Faculty of Mathematics and Physics, Charles University, <http://hdl.handle.net/11234/1-1983>.



This resource is also integrated in following services:



Share: [f](#) [t](#)

PML-TQ



LINDAT / CLARIAH-CZ

Citēšana

Universal Dependencies 2.0

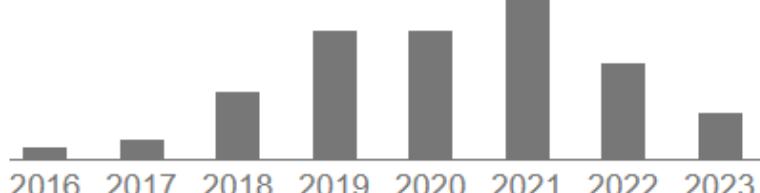
Autori Joakim Nivre, et al.

Publicēšanas
datums

Avots <http://hdl.handle.net/11234/1-1983>

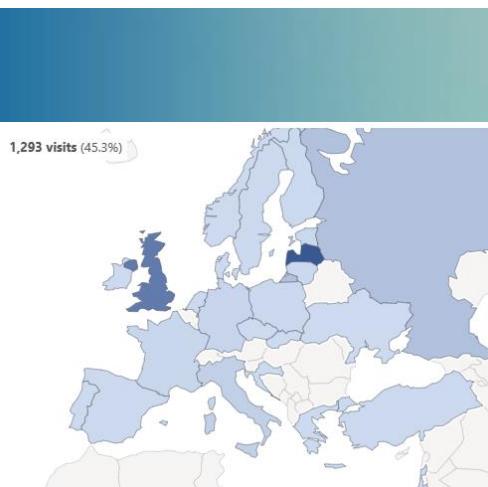
Apraksts UNIV-ST-ETIENNE| ENS-LYON| UNIV-LYON3| UNIV-PARIS7| ENS-PARIS| UNIV-TLN|
PRES_CLERMONT| CNRS| INRIA| UNIV-AMU| UNIV-LYON2| UNIV-PARIS3| LATTICE|
MODYCO| LLF| LPP| CERHAC| UNIV-LORRAINE| INRIA2| LORIA| LORIA-NLPKD|
PSL| USPC| LIS-LAB| IHRIM| UNIV-PARIS-LUMIERES| UDL| UNIV-PARIS| UP-
SOCIETES-HUMANITES| UNIV-PARIS-NANTERRE| IFRA-NIGERIA

Atsauču
kopskaits Minēts 312



Populārākie valodas resursi

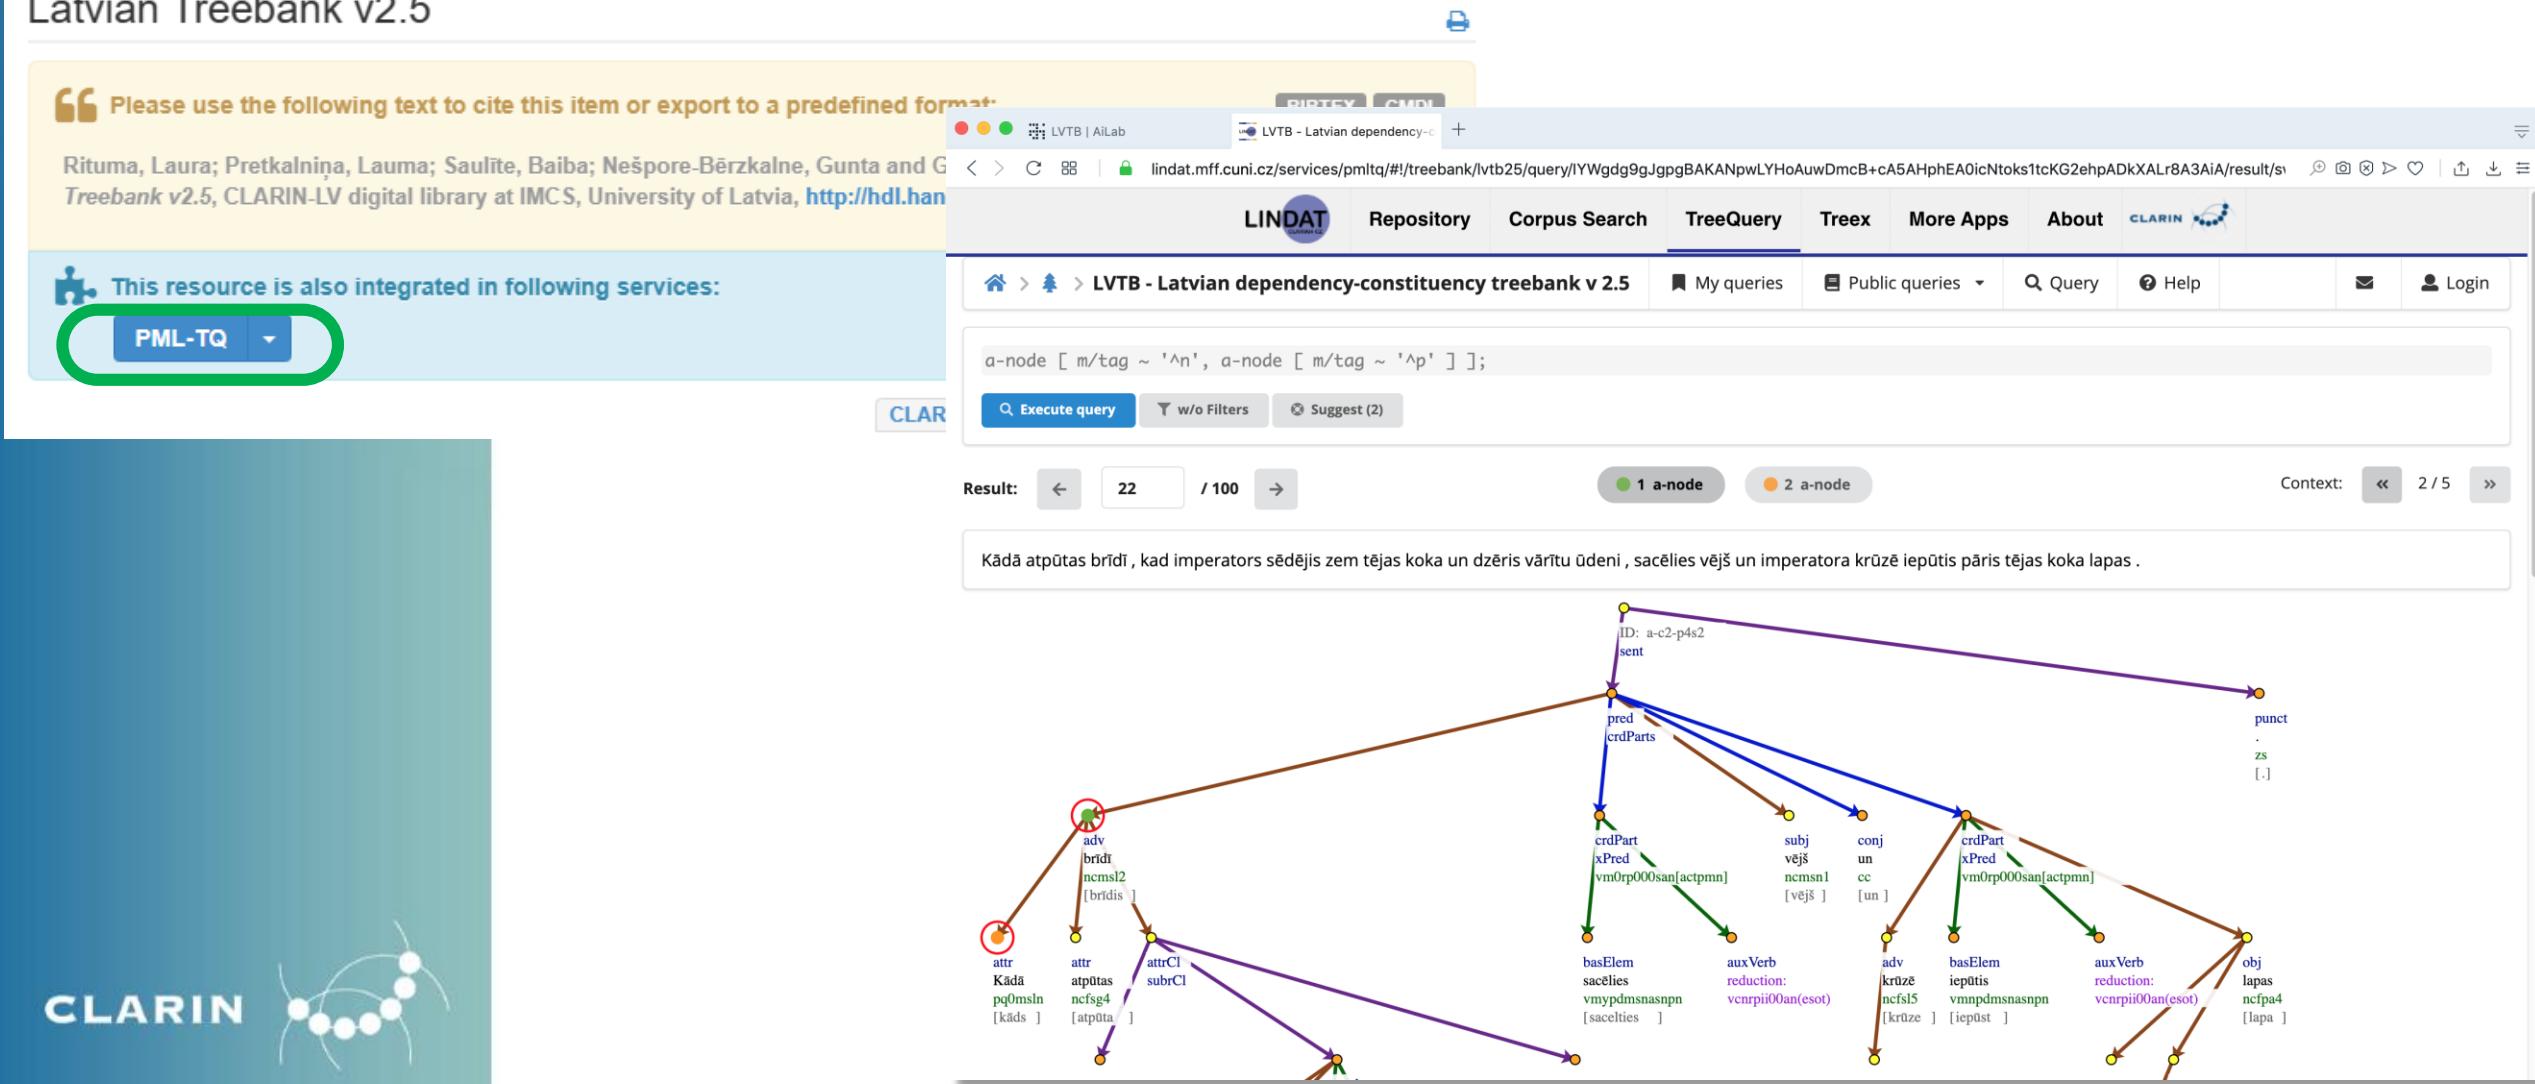
Visitor Map



Item/Handle	Number of views
Tēzaurs.lv 2020 (Spektors, Andrejs et al) (20.500.12574/9)	5352 [+bots: 6275]
Latvian Treebank v2.5 (Rituma, Laura et al) (20.500.12574/10)	3447 [+bots: 4109]
Tēzaurs.lv 2022 (Spektors, Andrejs et al) (20.500.12574/66)	3296 [+bots: 3494]
Balanced Corpus of Modern Latvian (LVK2018) (Levāne-Petrova, Kristīne et al) (20.500.12574/11)	3093 [+bots: 3206]
LVBERT - Latvian BERT (Znotiņš, Artūrs) (20.500.12574/43)	2967 [+bots: 3574]
NLP-PIPE: Latvian NLP Tool Pipeline (Znotiņš, Artūrs et al) (20.500.12574/4)	2685 [+bots: 2857]
The Corpus of Early Written Latvian (Andronova, Everita et al) (20.500.12574/12)	2514 [+bots: 2882]
Rainis (Spektors, Andrejs et al) (20.500.12574/41)	2413 [+bots: 2820]
Corpus of Latvian Pandemic Diaries 2020–2021 (Reinsone, Sanita et al) (20.500.12574/48)	2403 [+bots: 2800]
Latvian AMR Sembank (Znotiņš, Artūrs et al) (20.500.12574/40)	2360 [+bots: 2705]

Latviešu valodas resursi citu valstu CLARIN repozitorijos

Latvian Treebank v2.5



CLARIN virtuālā valodas resursu krātuve (VLO)

latvian

Showing 1 to 10 of 2,733 results for latvian (i)

Results per page: 10

Use the categories below to limit the search results to those matching the selected value(s).

Language

Collection

Type to filter or search for more

Europeana - National Library of Latvia: Collection 748774 (1332)

Europeana newspapers full-text (574)

Europeana - National Library of Latvia: Collection 569516 (396)

CLARIN:EL Catalogue (145)

Language resources and tools of AiLab IMCS UL (51)

LRT + Open Submissions Data & Tools (42)

LINDAT / CLARIAH-CZ Data & Tools (41)

Europeana - National Library of Latvia: Collection 57760 (31)

CLARIN.SI data & tools (18)

Rigascher Almanach für das Jahr ..., das 700ste seit Gründung der Stadt - 1858-1944 Rigascher Almanach für das Jahr ..., das 700ste seit Gründung der Stadt - 1858-1944 (16)

more...

<< < 1 2 3 4 5 6 7 8 9 10 > >>

Latvian Wikipedia
(Part of Language resources and tools of AiLab IMCS UL)
The corpus consists of all information published on Latvian Wikipedia until February 2022.

Latvian

Landing page for this record

TITUS Latvian
(Part of LRT + Open Submissions Data & Tools)
ca. 10.000 tokens; linked with relational database; XML-encoding in progress

Latvian

Landing page for this record

Bulgarian, Latvian
(Part of Pacific And Regional Archive for Digital Sources in Endangered Cultures (PARADISEC))
Newton's list comments: Balkanton (Bulgarian), Latvian, fables in Lettish Archive tape note: 00.00 AIATSIS announcement. Field Tape LT10, side 1. Balkanton, Latvian and Lettish languages. 25.35 End of Field Tape LT10, side 1. Tape LT10, side 2. 63.00 End of Field Tape LT10, side 2. AIATSIS Identifier: A16994. Language as given: Balkanton, Lettish

Bulgarian Latvian

+ VCR

+ VCR

+ VCR

<https://vlo.clarin.eu>

CLARIN valodas resursu kopas

Corpora

- Computer-Mediated Communication Corpora
- Corpora of Academic Texts
- Historical Corpora
- L2 Learner Corpora
- Legal Corpora
- Literary Corpora
- Manually Annotated Corpora
- Multimodal Corpora
- Newspaper Corpora
- Oral History Corpora
- Parallel Corpora
- Parliamentary Corpora
- Reference Corpora
- Sign Language Resources
- Spoken Corpora

Lexical Resources

- Language Models
- Lexica
- Dictionaries
- Conceptual Resources
- Glossaries
- Wordlists

Tools

- Corpus Query Tools
- Normalisation
- Named Entity Recognition
- Part-of-Speech Tagging and Lemmatisation
- Tools for Sentiment Analysis



[Resource Families | CLARIN ERIC](#)

CLARIN valodas resursu kopas

Corpora

- Computer-Mediated Communication Corpora
- Corpora of Academic Texts
- Historical Corpora
- L2 Learner Corpora
- Legal Corpora
- Literary Corpora
- Manually Annotated Corpora
- Multimodal Corpora
- Newspaper Corpora
- Oral History Corpora
- Parallel Corpora
- Parliamentary Corpora
- Reference Corpora
- Sign Language Resources
- Spoken Corpora

Lexical Resources

- Language Models
- Lexica
- Dictionaries
- Conceptual Resources
- Glossaries

Tools

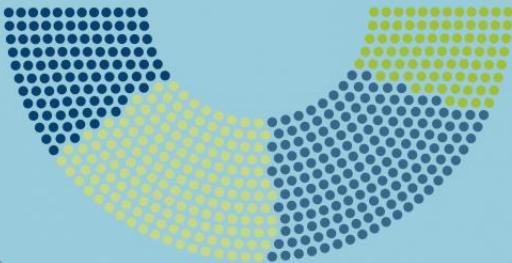
- Corpus Query Tools
- Normalisation
- Named Entity Recognition
- Part-of-Speech Tagging and Lemmatisation
- Tools for Sentiment Analysis

Corpora of Academic Texts

Corpora of academic texts contain scholarly writing, such as research papers, essays and abstracts published in academic journals, conference proceedings, and edited volumes, theses written by students at undergraduate and graduate levels, and scientific monographs.

The CLARIN ERIC infrastructure gives access to 24 corpora of academic texts, 2 of which are multilingual and 22 monolingual. The available corpora contain scholarly texts in the following 11 languages: Czech, English, Estonian, Finnish, French, German, Greek, Russian, Slovenian, Spanish, and Swedish. More than 15 different scholarly disciplines are represented, with the most prominent being linguistics, computer science, economics, and medicine. The majority of the corpora are richly tagged and are available under public licences.

ParlaMint



Sadarbība, veidojot kopīgus valodas resursus

Corpus CLARIN.SI Data & Tools

Multilingual comparable corpora of parliamentary debates ParlaMint 2.0 

(CLARIN ERIC / 2021-05-10)

Author(s):

Erjavec, Tomaž ; Ogrodniczuk, Maciej ; Osenova, Petya ; Ljubešić, Nikola ; Simov, Kiril ; Grigorova, Vladislava ; Rudolf, Michał ; Pančur, Andrej ; Kopp, Matyáš ; Barkarson, Starkaður ; Steingrímsson, Steinþór ; van der Pol, Henk ; Depoorter, Griet ; de Does, Jesse ; Jongejan, Bart ; Haltrup Hansen, Dorte ; Navarretta, Costanza ; Calzada Pérez, María ; de Macedo, Luciana D. ; van Heusden, Ruben ; Marx, Maarten ; Çöltekin, Çağrı ; Coole, Matthew ; Agnoloni, Tommaso ; Frontini, Francesca ; Montemagni, Simonetta ; Quochi, Valeria ; Venturi, Giulia ; Ruisi, Manuela ; Marchetti, Carlo ; Battistoni, Roberto ; Sebők, Miklós ; Ring, Orsolya ; Darģis, Roberts ; Utka, Andrius ; Petkevičius, Mindaugas ; Briedienė, Monika ; Krilavičius, Tomas ; Morkevičius, Vaidas

This item contains 17 files (2.03 GB). 

Publicly Available 



Showcase 2: 'COVID' keywords

Italy	Poland	Slovenia	UK
pandemic	pandemic	epidemic	covid
covid	bell	ventilator	coronavirus
covid-19	coronavirus	coronavirus	furlough
coronavirus	covid-19	covid-19	lockdown
lockdown	mask	virus	pandemic
mask	epidemic	quarantine	distancing
recovery	quarantine	corona	ppe
European Stability Mechanism (ESM)	Kukiz15	mask	inaudible
distancing	the Left	pandemic	
fund	shield	anti-corona (adj)	
serologic	anti-crisis	/paramilitary group/	
virus	covid	/name/	

[Parliamentary Debates
in the COVID Times](#)

Helsinki DH Hackathon 21

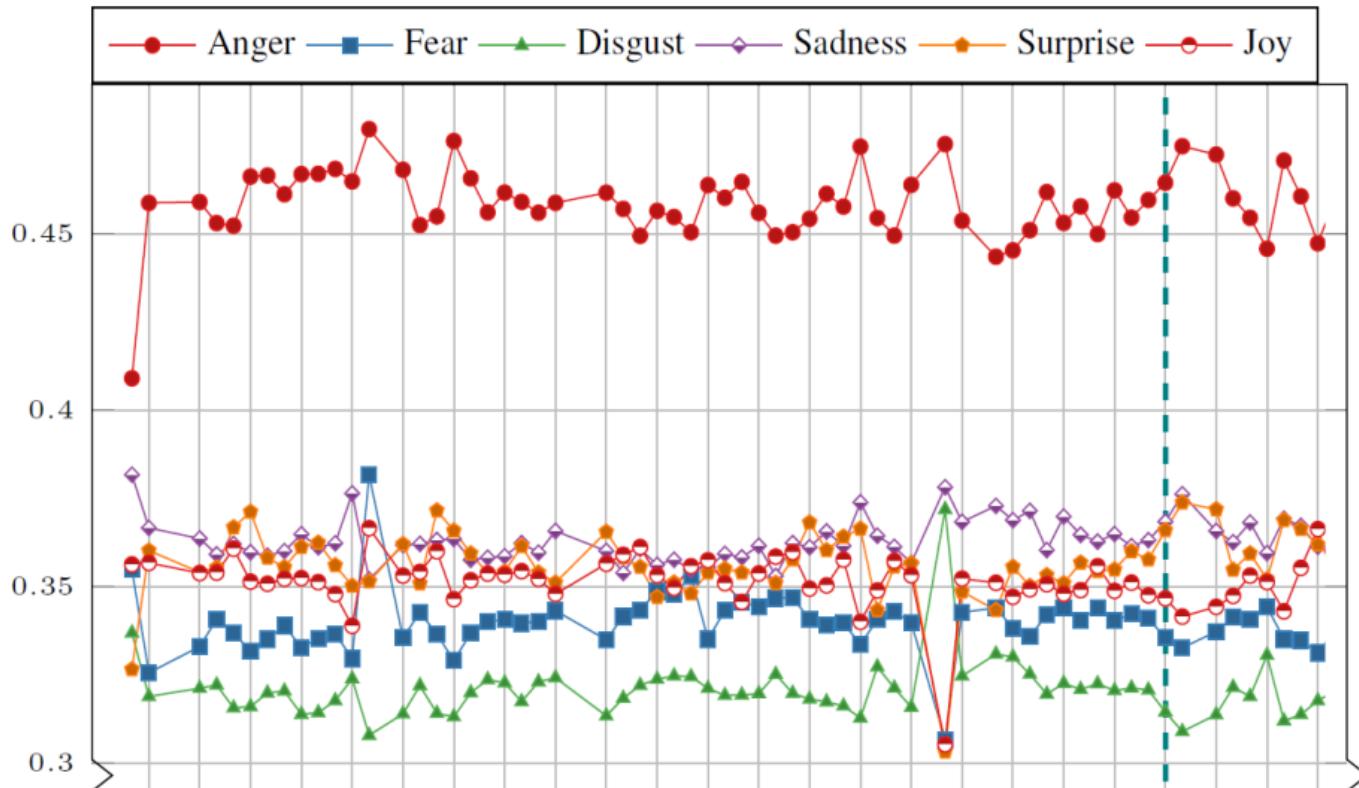




Showcase 6: Emotions Running High

Kurtoğlu and Çöltekin (2022).
[Emotions Running High?](#)

- Investigating polarization of politics by assigning emotion scores to speeches
- anger being the dominant emotion
- the ruling party showing more stable emotions compared to the opposition



CLARIN zināšanu centrs morfoloģiski bagātām valodām SAFMORIL

- SAFMORIL ir CLARIN zināšanu centrs (knowledge centre) morfoloģiski bagātām valodām
- SAFMORIL konsultē digitālo humanitāro zinātņu pētniekus un valodu tehnoloģiju izstrādātāju par valodas resursiem un rīkiem morfoloģiski bagātām valodām
- SAFMORIL apvienojušās Helsinku Universitāte, Trumses Universitāte, Latvijas Universitātes Matemātikas un Informātikas institūts un Vītauta Dīžā Universitāte

Konference "Jaunākie valodas resursi un rīki digitālajām humanitārajām zinātnēm"

2023. gada 12. septembrī Latvijas Universitātes Matemātikas un informātikas institūts sadarbībā ar digitalhumanities.lv un DHELI projektu rīkoja ikgadējo CLARIN-LV konferenci "Jaunākie valodas resursi un rīki digitālajām humanitārajām zinātnēm". Konferences materiāli:

- [Kaspars Bērziņš \(VPC\)](#). Augstākās izglītības un zinātnes IT koplietošanas pakalpojumu centrs (VPC) un datu kuratoru projekts
- [Maciej Ogrodniczuk \(CLARIN ERIC\)](#). ParlaMint: Multilingual Comparable Corpora of Parliamentary Debates for Digital Humanities
- [Edward Gray \(DARIAH EU\)](#). The Digital Research Infrastructure for the Arts and Humanities: How DARIAH Helps Enable SSH Researchers
- [Inguna Skadiņa \(LU MII\)](#). CLARIN-LV - solis pretī valodu digitālai vienlīdzībai
- [Anta Trumpa un Sanda Rapa \(LU LaVI\)](#). Valodas digitalizācija: no pirmajiem rakstu avotiem līdz mūsdienām
- [Anda Baklāne \(LNB\)](#). Digitālo pakalpojumu aktualitātes Latvijas Nacionālajā bibliotēkā
- [Antra Kļavinska \(RTA\)](#). Latgaliešu valodas digitālie resursi: paveiktais, klupšanas akmeņi un iespējas
- [Sanita Reinsone un Sandis Laime \(LU LFMI\)](#). Humma.lv – ceļā uz digitālo platformu humanitārajām un mākslas zinātnēm
- [Valts Ernštreits \(LU Lībiešu institūts\)](#). Lībiešu valodas datu ieguve un tās nākotnes perspektīvas
- [Baiba Saulīte un Ilze Auziņa \(LU MII\)](#). Tēzaurs.lv un Korpuss.lv jaunumi



Seminārs "Runas korpusu izveide un to izmantojums"

2023. gada 18. maijā notika *digitalhumanities.lv* seminārs sadarbībā ar Clarin-LV un DARIAH-EU "Runas korpusu izveide un to izmantojums". Semināra materiāli:

- [Ilze Auziņa](#). Runas korpusu nozīme valodu tehnoloģiju izstrādē.
- [Antra Kļavinska](#). Mūsdieni latgaliešu runas korpusa izveide mazāk lietoto valodu dokumentēšanas kontekstā.
- [Ilze Auziņa un Guna Rābante-Buša](#). Runas datu apstrāde programmā ELAN.

Citi būtiski CLARIN piedāvājumi

Learning Hub

- Learning and Training Resources
- Training and Workshops
- Digital Humanities Course Registry
- Notebooks in Education

Funding Hub

- Workshop Funding
- User Involvement Funding
- Teaching with CLARIN
- Trainer Network Programme
- Mobility Grants
- Resource Families Project Funding

[Learning Hub | CLARIN ERIC](#)

[CLARIN Funding Hub | CLARIN ERIC](#)

CLARIN konference

- iespēja piedalīties ikvienam konsorcija partnerim (atbalsts referātiem)
- īpašs atbalsts doktorantiem



Konsorcijs



Latvijas Universitātes
Matemātikas un informātikas institūts



Paldies par uzmanību!



VPP-LETONIKA-2021/1-0006



2.3.1.1.i.0/1/22/I/CFLA/002

