



TEI Modelling of the Lexicographic Data

Krzysztof Nowak

Dorota Mika

Wojciech Łukasik



Fundusze
Europejskie
Inteligentny Rozwój



Rzeczpospolita
Polska

Unia Europejska
Europejski Fundusz
Rozwoju Regionalnego



The Dariah.Lab Project

Lexicographic Resources

The workflow

Discussion

- delimiting lexical units
- defining senses
- representing language use
- placing in time and space

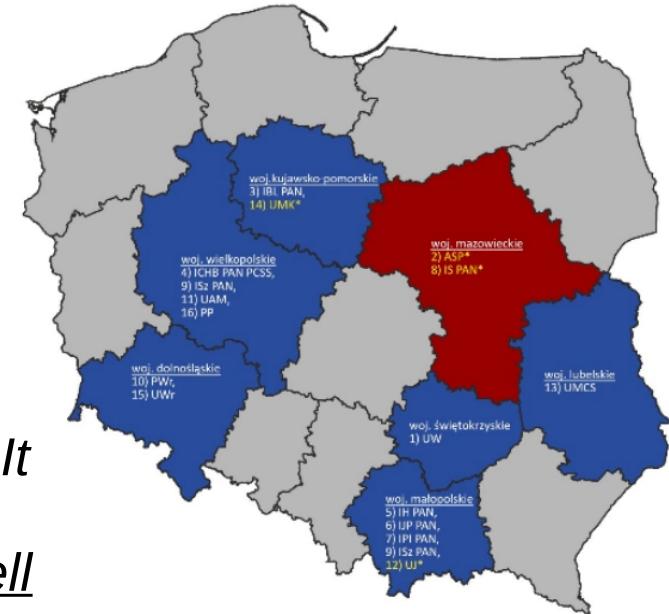


WWW: <https://lab.dariah.pl/>

Period: January 2021 - December 2023

Funding: European Union

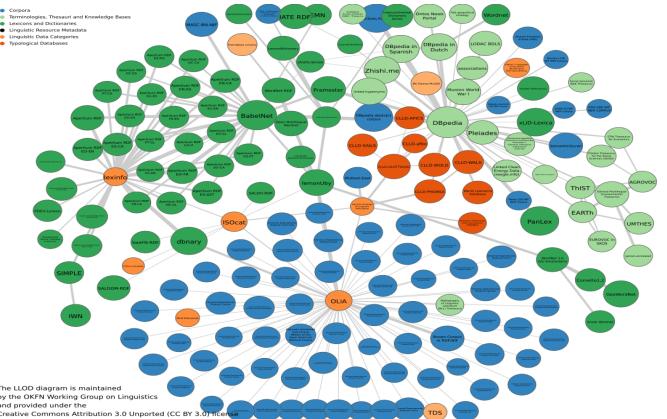
Goal: *Dariah.lab is a research infrastructure for the arts and humanities built in the DARIAH-PL project. It is designed to acquire, store and integrate cultural data from the humanities and social sciences, as well as to process, visualize, and share digital resources.*
(Source: Project's website)

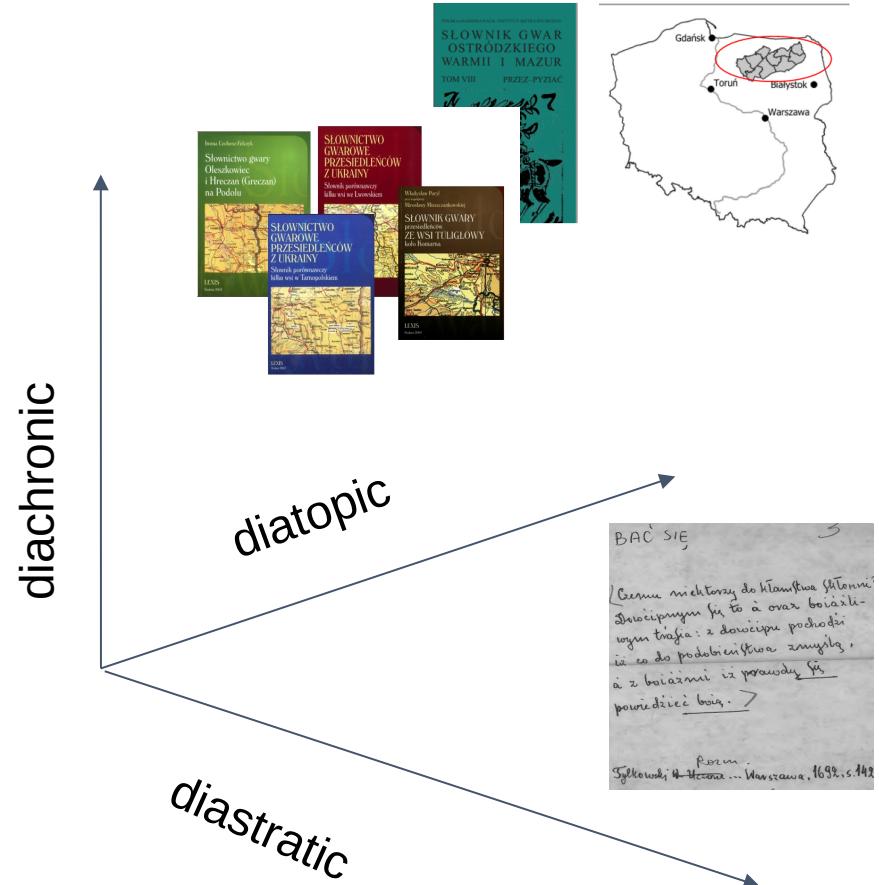
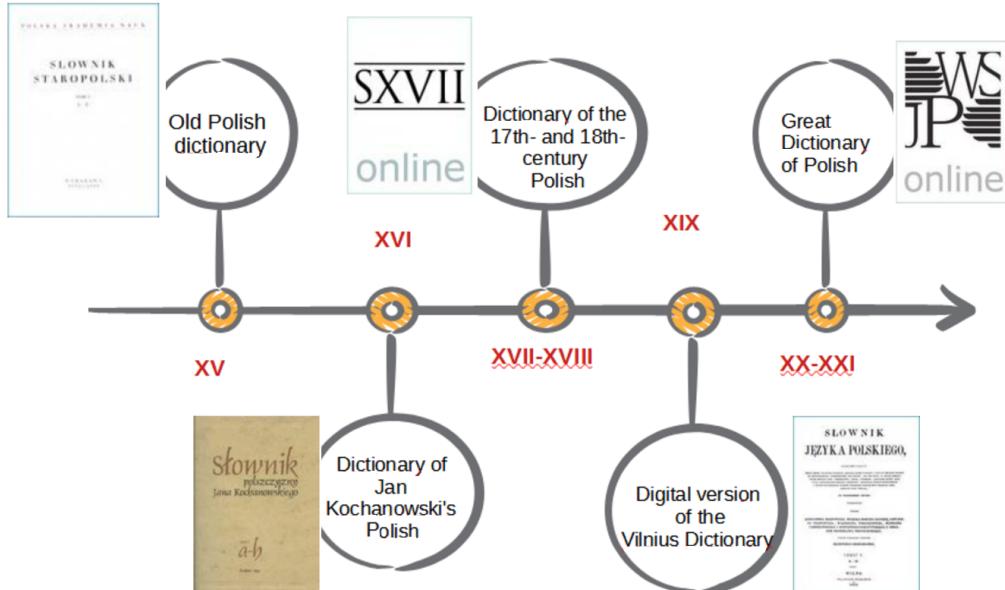


1. The Spoken Component of the Polish Corpus of 2011-2020 (in collaboration with the Institute of Computer Science PAS)

2. Integrated Access to the Institute's Dictionaries and Lexicographic Data

- web platform for data discovery
- API for automated access





Wojciech Łukasik

- computational literary studies

Dorota Mika

- linguistics and lexicography of Old Polish

Krzysztof Nowak

- linguistics and lexicography of Medieval Latin

```

<entryFree n="BUC1" type="hom">
  <form>
    <orth>BUC</orth>
    <gen>rz</gen>
  </form>
  <sense><lbl>1.</lbl><def>ktoś o wydatny
      dziecko</def>: <quote>Od ny/ fśis
      <usg type="geo">Bobowo st-gdań.</usg>
    <sense><lbl>2.</lbl><def>ktoś małomówny
    <sense><lbl>3.</lbl><def>przezw<usg/></def>kt
      taki buc, pšeļy i šy ny uodezv^
      kroś.</usg></sense>
  </entryFree>

```

BUC rz 1. 'ktoś o wydatnych po
liczkach, pucołowaty, ` zwłaszcza
dziecko': Od ny/ fśiske byii take
buce. Fśiske jejer/ ęcī Bobowo st-
gdań.
2. 'ktoś małomówny': Ostrowce bus.
**3. przezw 'ktoś niesympatyczny, za
rozumiały':** To taki buc, pšeļ^y i
šy ny uodezv^ Bobrka kroś.

I. BUC rz 1. 'ktoś o wydatnych po
liczkach, pucołowaty, ` zwłaszcza dziecko':
Od ny/ fśiske býli také buce. Fśiske
jejer/ ęcī Bobowo st-gdań.

2. 'ktoś małomówny': Ostrowce bus.
**3. przezw 'ktoś niesympatyczny, za
rozumiały':** To taki buc, pšeļ^y i šy ny
uodezv^ Bobrka kroś.

4. 'ktoś niezaradny, niedolega': Tě
buce stári. Ale to běl buc. Ta so vzala
ale buca pn i pd ok Žarnowca wej
S I 81.

5. 'przezw nadawane mieszkańcom wsi':
Buc, bamber — tak nazywają ludzi
ze wsi Oborniki.

Jałowica, Jelowica *formy: n. sg. jałowica* 35
 1400 *StPPP VIII* 929, XV *p. post. PF III* 286;
jełowica 1453 *AGZ XIV* 388; ~ *d. sg. jałowicy*
BZ Deut 21, 4; ~ *ac. sg. jałowicę* 1423 *StPPP*
II nr 1910, 1439 *AGZ XI* 158, 1440 *AGZ XI*
165, etc.; ~ *i. sg. jałowicą* *BZ Deut* 21, 6;
 ~ *n. du. jalowicy* 1446 *AGZ XI* 272; ~ *ac. du.*
jałowicy 1453 *AGZ XI* 386; ~ *ac. pl. jałowice*
 1477 *StPPP II nr 4194*, 1484 *AGZ XV* 531.

Znaczenia: 1. *iuvencia, vitula*: Pro
 1400 *StPPP VIII* 92
 dare debet 1423 *S*
 terciam penam ma
 1439 *AGZ XI* 158;
 plenam... facultate
 ialowyczą 1440 *ib.*
 luet ialouicza 1442
 czelne et due ialo
 Due ialowycz trzec
 nyestany ialowiczą

40 **Jałowiec** bot. 'jałowiec pospolity, krzew lub
 jego owoc, *Juniperus communis L.*': Yalowyecz
 bacce iuniperi 1419 *Rost* nr 5069; Jalowyecz
 iuniperus 1437 *ib.* nr 10836, *sim.* 1460 *ib.*
 nr 3602, *ca 1465 ib.* nr 3929, *etc.*, XV *p. post.*
R LIII 66, *ca 1500 Erz* 23; Yalouiecž iuniperum
 1444 *R XXIII* 302, *sim. ca 1500 Erz* 23;
 Jalowczą (*GlWroc* 85v. 133v, *R XLVII* 353:
 yalowecz) proiecitque se et dormiuit sub vmbra
 iuniperii (III Reg 19, 5) XV *p. pr. SKJ I* 303;
 Jalowecz XV *med. PulKras* 33; Iuniperi vlg.
 jalowecz 1456 *R XXXIII* 183; Jalovyecz juniperum
 1463 *PF V* 12; Yalowiecž yuniperius
 1464 *Rost* nr 4819; Yalowecž iuniperus 1472 *ib.*
 nr 93, *sim. 1491 ib.* nr 11065; Yalovyeč iuniperus
 1478 *ib.* nr 2110; Yalovyeč *ib.* nr 2266;
 *Valovyeč iuniperus *ca 1500 ib.* nr 2060.

50 **Jałowięć** 'cielę, ciełatko, vitulus': Vitulum al.
 jalową 1429 *ArchCastrCrac III* 188; Petrus...
 tres vaccas, duo jalowata presentis anni al.

55

Dictionary of Old Polish

BAZGRAĆ (SIE) *Formy: 3 os lp*
czter bażgro || bażgże ||- Mszana G lim;
 ~ *bażgrać ||- Mszana G lim;* ~ *bez-*
grać ||- ok Sejn suw PKJP II 2 s 51;

CHŁOPYSIO, CHŁOPYSIU, CHŁO- 3 os lp *czter bezgra ||-*
RŁTN XXI 157; Chłopysio Kuj Kuj II 285; JP II 2 s 51; ~ *pazgrać*
 ~ *χłopysu ||- Domaniewek lęcz PJPAN*; *Lopienno wag PKJ*
XXXVII 309; ~ χłopys ||- Libiszów opocz RŁTN XXI 157; ||- Domaniewek lęcz PJPAN
XXXVII 309; Kramsk koniń; χłopys Pod-
różna złotow; ~ W lp chłopysin Pęcav lęcz,
LL VI 1-2 s 85.

Znaczenie: 'chłopczyk': *U*
myśl'i, że ty tu som doż rade K
χłopysu, pūy, duoestańeš japk
złotow; Libiszów opocz RŁTN
Domaniewek lęcz PJPAN XXXV
maniewek lęcz PJPAN XXXV
lęcz LL VI 1-2 s 85; Kuj Kuj I

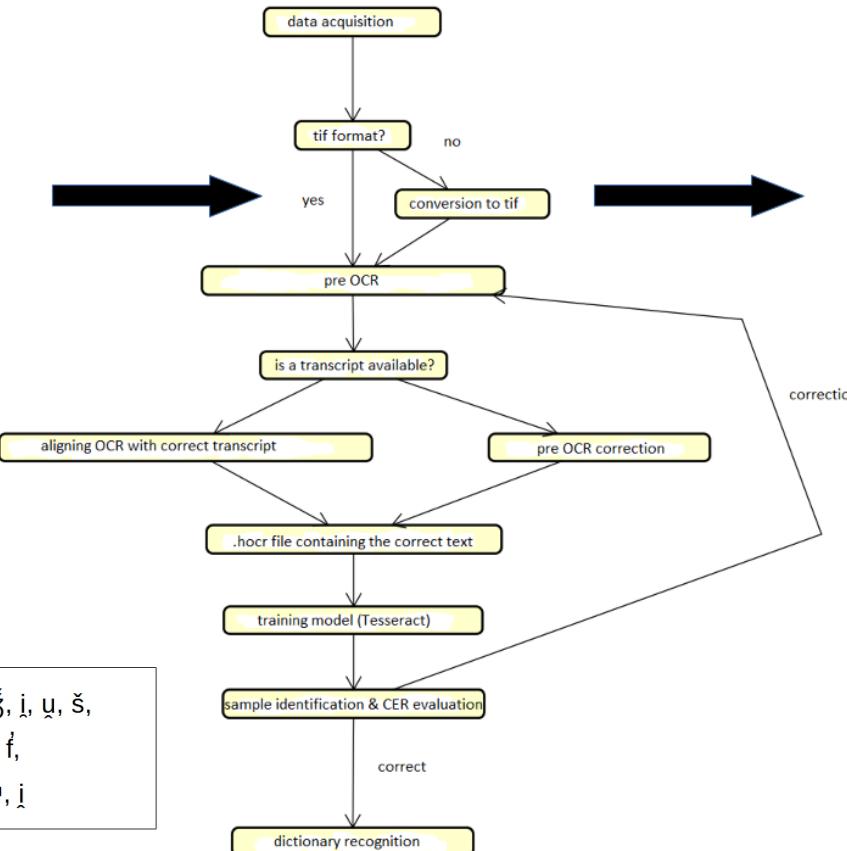
I. BOSAK, BOSAKA, BÓSAKI przy-
 słów *Formy:* Bosak [rzd] *Krościenko*
n-tar MAGP VIII m 364 s 56; bosok
Trojanów miń-maz jw m 364; ~ *bosoka*
Domaniewek lęcz PJPAN XXXIII 47;
Domaszew gar; Złotniki kal; blosoka
Obra wolsz; bosaka [rzd] *Bąków rad*
MAGP VIII m 365; ~ *bosaki Wlynice*
radomsz RŁTN XX 249; ~ *typ bossaka:*
Bąków rad MAGP VIII m 364 s 56; || *bo-*
saka jw m 365 s 58; Mokrzesz częs MAGP
VIII m 364; Bolmin kiel RŁTN XX 250;
Kajetanów ilż jw; || *Jelnia opocz jw;* ~
typ boscaka: *Alojżów ilż MAGP VIII*
m 365; || *bosaka AWK III 377; Opatko-*

Dictionary of Polish Dialects

TIFF

OCR

Boruta	395	Borusska
stawiła naczynia z potrawami Przyj. Ludu VI 127.	JO	
II. BORUTA "nazwa krowy"; Boruta Maguny i ok [Grodno ZSRR] Polgow II 169.	JO	
Boruwał zob. I. BOROWĄC		
Borwiniec zob. BARWINEK		
BORYJOWICA Forma: Boryjuwica Przewrotne rzesz.		
Znaczenie: "gnójówka"; jw. JO		
Boryjowica zob. BORYJOWICA		
BORYJÓWKA "gnójówka": Boryjufka Przewrotne rzesz.	JO	
BORYKAĆ (SIE) "plądrować, szukać przerwować"; Borykać Krak K I 108.		
Borykać się 1. "szamotać się, walczyć"; iśc w zapasy": Borykać się Krak jw.		
2. "pokonywać trudności, zmagać się z przeciwnikami; męczyć się": Tagaj się borykają aż do roku tyślineń stycznych pełni Nieborów [Cieszym Czel.] PIJP I 46; Żyl z pracy rąk swoich, a tak przewrócił się do drzwi i zasypał i tak się w ty błyśnieć swoj borykali Zarawiecki przew LL I 3 s 26. Capo tyče covek se tyliko borykani, nis ne uzy Samocice dąb-tar. Se zužok capa tyče borykou ji tero na stare lata nis nis mo Domanieckie lęce PIJPAN XXXIII 47; Krak K I 108; Złotniki kal: ~ B. się z cym: Boryko ſe z ružnymi nescydcamy Studienice rad RZLN XX 249.	JO	
3. "starać się, zabierać coś": Już wylegeli si maz robacy, h o robacy fe borykali luža, kpti si Niedzica w ter. ZNUJ CCLXXXVIII 120.	JO	
BORYKI blp "zapasy": Pastuch [...] nuz „w boryki z kudlatym” [wilkolakiem] Bodzentyn kiel Ludu I 294. JO		
BORYN* z 1 n-tar PIJ		
BORYN borynika J borka na we wad E BOR (Spesiesi PIJPAN)		
combining characters: q, 3, ź, ź, ĩ, ĩ, ū, ř,		
č, ž, ś, ĸ, ĺ, ġ, ĺ, ꝑ, ꝑ, ꝑ, ꝑ, ꝑ, ꝑ, ꝑ,		
ꝑ,		



Boruta
stawiła naczynia z potrawami Przyj.- Ludu VI 127. JO
II. BORUTA "nazwa krowy": Boruta Maguny i ok [Grodno ZSRR] Polgow II 169. JO
Boruwał zob. I. BOROWĄC
Borwiniec zob. BARWINEK
BORYJOWICA Forma: Boryjuwica Przewrotne rzesz.
Znaczenie: "gnójówka"; jw. JO
Boryjowica zob. BORYJOWICA
BORYJÓWKA gnójówka": Boryjufka Przewrotne rzesz. JO
BORYKAĆ (SIE) "plądrować, szukać- ja przewracać: Borykać Krak K I 108. Borykać się 1. "szamotać się, walczyć"; iśc w zapasy": Borykać się Krak jw.
2. "pokonywać trudności, zmagać się z przeciwnikami; męczyć się": Tagaj się borykają aż do roku tyślineń stycznych pełni Nieborów [Cieszym Czel.] PIJP I 46; Żyl z pracy rąk swoich, a tak przewrócił się do drzwi i zasypał i tak się w ty błyśnieć swoj borykali Zarawiecki przew LL I 3 s 26. Capo tyče covek se tyliko borykani, nis ne uzy Samocice dąb-tar. Se zužok capa tyče borykou ji tero na stare lata nis nis mo Domanieckie lęce PIJPAN XXXIII 47; Krak K I 108; Złotniki kal: — B. się z cym: Boryko ſe z ružnymi nescydcamy Studienice rad RZLN XX 249.
3. "starać się, zabierać coś": Już vylegeli si maz robacy, h o robacy fe borykali luža, kpti si Niedzica w ter. ZNUJ CCLXXXVIII 120.
BORYKI blp "zapasy": Pastuch [...] nuz „w boryki z kudlatym” [wilkolakiem] Bodzentyn kiel Ludu I 294. JO
BORYN *naczynie do przewozienia żętycy z hali do wsi": Boryna Dzianisz n-tar PIJP IV 41. JO
BORYNKA "dzbanek": Borynka sti borynka Rabka-Zaryte n-tar; — "blaszana bańska na mleko, jagody": Borynka Za- woja wad PIJP XIII 64. JO

Experiments

- grobid-dictionaries
- other ML solutions

Solution: custom Python (*CLARIN-PL) and XSLT scripts

- punctuation marks
- anchoring strings: labels, abbreviations, initials etc.
- location
- no font style info

Motivation

- (slightly more) formal resource's description
- documenting
 - annotation choices and semantics
 - original rendering
- generating scheme and documentation

Principles

- preserving textuality for quoting and display
- exposing data to enrichment
 - aligning dictionary parts
 - dates, places, sources etc.
- reconciling meta-languages

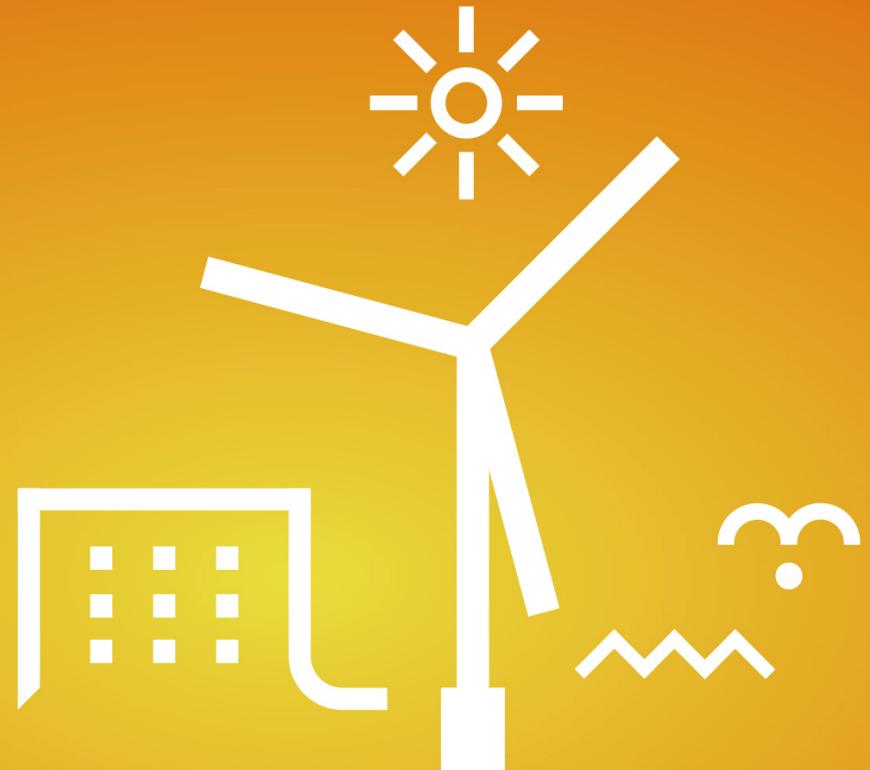
```
<schemaSpec ident="ijpsgp"
             source="ijp_all.compiled.odd">
  <elementSpec ident="entryFree" mode="change">
    <gloss xml:lang="pl">hasło</gloss>
    <desc xml:lang="pl">hasło słownikowe</desc>
    <attList org="group">
      <attDef ident="type" mode="change">
        <valList type="closed" mode="change">
          <valItem ident="main" mode="change">
            <gloss xml:lang="pl">zwykłe</gloss>
            <desc xml:lang="pl">zwykłe hasło</desc>
          </valItem>
        </attDef>
      </attList>
    </elementSpec>
  </schemaSpec>
```

Delimiting lexical units

Linguistic evidence: time and space

Taking stance: critical apparatus

Citation strategies



*BAŁAŁAJKA

```
<entryFree type="empty">
  <form type="lemma">
    <lbl>*</lbl>
    <orth norm="bałałajka">BAŁAŁAJKA</orth>
  </form>
</entryFree>
```



'a balalaika'

```
<!-- main entry: a participle -->
<entryFree>
    <!-- related entry: a derived noun-->
    <re/>
    <!-- related entry: a derived noun -->
    <re/>
    <!-- related entry: a derived prepositional phrase -->
    <re/>
</entryFree>
```

GIĘTY 1. *imb od cz giąć (zob.)*

2. 'spręzysty, uginający się, elastyczny;
giętki': bijł nie zuōmje še, je gąnte chojn 5.

Gięta w użyciu rz, dziec 'o lodzie uginających się przy chodzeniu po nim': nie lątai-va ius pło góče, bło jesce χtury z náz uoká-pe še v vlože dqb-tar 5.

Gięte w użyciu rz 'nosidła': tarn PAE IV m 241; boch jw.

Po giętu 'w pozycji zgiętej, pochylonej': to my tag_mušeli χložić pło góentu, žeby še ne zadušić ciesz ZNUJ 495 s 113. AN

```
<sense>
  <lbl>~</lbl>
  <usg type="colloc">jałowcowe drzewo</usg>
  <usg type="dom">bot.</usg>
  <def xml:lang="pl">jałowiec pospolity</def>
  <def xml:lang="la">Juniperus communis L.</def>
</sense>
```



‘juniper tree’

```
<sense xml:id="Sstp_Jałmużnik_sense_1">
    <def xml:lang="pl">dający jalmużnę lub z urzędu
        rozdzielający jalmużnę</def>
    <def xml:lang="la">qui eleemosynam dat vel ex officio
        distribuit</def>
    <lbl>(?)</lbl>
    <certainty locus="value" degree="0.5" match="orth"/>
</sense>
```

... word senses

```
<form type="lemma">
    <orth norm="grzycka">GRZYCKA</orth>
    <lbl>[?]</lbl>
    <certainty degree="0.5" locus="value" match="orth"/>
</form>
```

... word forms

```
<cit xml:lang="pl">
    <quote>Boryna</quote>
</cit>
<usg type="geo">
    <placeName>
        <settlement>Dzianisz</settlement>
        <lbl type="geo">
            <region type="county" when="1986">
                n-tar
            </region>
        </lbl>
    </placeName>
</usg>
<cit>
    <bibl>
        <title type="abbr">PIJP</title>
        <biblScope unit="volume">IV</biblScope>
        <biblScope unit="page">41</biblScope>
    </bibl>
</cit>
```



Coordinates: 49°19'53"N 19°52'2"E

Country		Poland
Voivodeship		Lesser Poland
County		Tatra
Gmina		Kościelisko

```
<cit>
  <quote  xml:id="quote-ialmuzna-1"> ...</quote>
  <bibl>
    <title type="abbr" xml:id="BZ-1">BZ</title>
    <biblScope unit="chapter">2</biblScope>,
    <biblScope unit="line">16</biblScope>
  </bibl>
</cit>
```

```
<cit>
  <ref corresp="#quote-ialmuzna-1" type="sim">sim.</ref>
  <bibl>
    <ref target="#BZ-1">ib.</ref>
    <biblScope unit="chapter">12</biblScope>,
    <biblScope unit="line">9</biblScope>
  </bibl>
</cit>
```

```
<cit>
  <quote>Tegodlya,
    <seg xml:id="seg-4">kyedy czynysch yamvzna</seg>
    <note>
      (<gloss target="#seg-4" resp="#lexicographer">
        cum... facis eleemosynam
      </gloss>
      <bibl type="bible">
        <title>Mat</title>
        <biblScope unit="chapter">6</biblScope>
        <biblScope unit="line">2</biblScope>
      </bibl>
    </note>, nye day przed sobą trąbycz ...
  </quote>
  <bibl>
    <title type="abbr">Rozm</title>
    <biblScope unit="page" from="271" to="272">271-2</biblScope>
  </bibl>
</cit>
```

```
<cit>
  <quote>
    Ial̄mvsznyṁ
    <corr resp="#lexicograph" xml:id="corr-1">nacznem</corr>
    <note>(
      <lbl>leg.</lbl>
      <sic corresp="#corr-1">nędznem</sic>
    )</note> nye daval
  </quote>
</cit>
```

Keep track of advances in token-level text structuring

- sharing tools and expertise

Discuss with content creators

Take annotators' feedback into account

Work with ODD

- describe the resource
- document annotation choices
- explain assumptions about document semantics
- generate multi-lingual documentation

Know when to stop