

Počítačová lexikografie

XML, standardy

Adam Rambousek



Počítačová lexikografie
XML, standardy
Adam Rambousek

Počítačová lexikografie

XML, standardy

Adam Rambořík

XML

- eXtensible Markup Language - znakovací jazyk pravidla, jak má vypadat správně vytvořený dokument
 - studnie strojového spracování a výměny informací
 - konkrétní názvy znaků určuje uživatel (standardy, vlastnosti, elementy)
 - elementy: <ns1:obsah>/<ns2:obs>
 - bez obsahu lze <ns1:obsah/> zkrátit na <ns1:obs>
 - atributy: <ns1:obsah attr1="value1">



- správné závorky známeck
- správně: <a>b<ext>/b
- špatně: <a>b<ext>
- speciálne znaky se přepisují na entity (např. <)

 - <, >, &

Popis a kontrahent

TEI



- Text Encoding Initiative
- <http://www.tei-c.org/>
 - TEI Guidelines (aktuální verze 5 z roku 2007)
 - XML formát pro semantický popis textových dokumentů
 - velký rozsah známk
 - TEI - očekávané verze: >90% početně 99 % užívání
 - významné funkce: drahlední hry, dokumentace, slovníky, katalogy, grafy, rukopisy, zápisníky, edikty, změny textu, notové záznamy
 - mimoře: sada XSLT pro převod na LaTeX, docx, EPUB, HTML



```
<div type="Act" n="1">
  <head>ACT 1</head>
  <div type="Scene" n="1">
    <head>SCENE 1</head>
    <stage rends>Hal,
    &sentinel, at sever
    &sp>
      <speaker>Bar
        <do part>"Y
      </sp>
      <sp>
        <speaker>
          <do Nay, at
        </sp>
```

LMF

- Lexical Markup Framework
 - <http://www.lexicalmarkupframework.org/>
 - ISO-24613:2008
 - jednotný model pro tvorbu lexikálních zdrojů
 - důraz na strojovou spracování a rozličitost
 - DTD, XML, JSON, epos, LaTeX



```

<Wznamy>
  <!ELEMENT wznamy (part-of-speech|definition|comment)*>
  <!ELEMENT part-of-speech (language|script|script-form)>
  <!ELEMENT definition (text|examples)*>
  <!ELEMENT comment (text|examples)*>

```

Ukázka

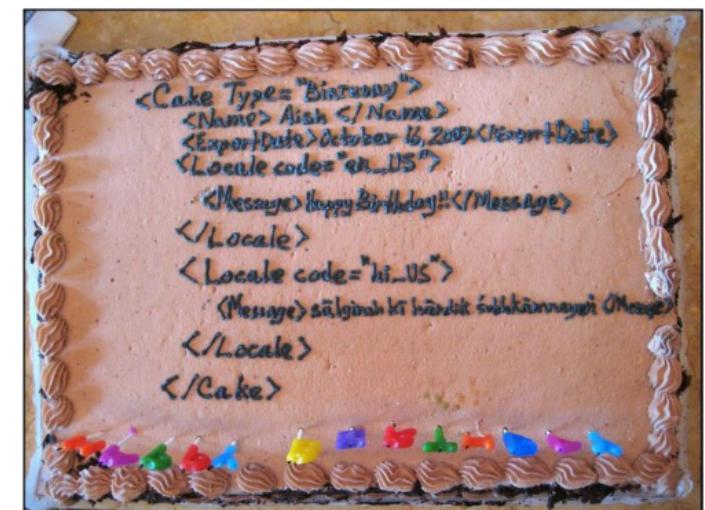
```
SSC  
-sigma  
-de [de] [de]  
-graves [e:gravz]  
-sigma  
-sigma-1 [e:ga:m]  
-sigma-2 [e:ga:m]  
-sigma-3 [e:ga:m]  
-sigma-4 [e:ga:m]  
-sigma-5 [e:ga:m]  
-sigma-6 [e:ga:m]  
-sigma-7 [e:ga:m]  
-sigma-8 [e:ga:m]  
-sigma-9 [e:ga:m]  
-sigma-10 [e:ga:m]  
-sigma-11 [e:ga:m]  
-sigma-12 [e:ga:m]  
-sigma-13 [e:ga:m]  
-sigma-14 [e:ga:m]  
-sigma-15 [e:ga:m]  
-sigma-16 [e:ga:m]  
-sigma-17 [e:ga:m]  
-sigma-18 [e:ga:m]  
-sigma-19 [e:ga:m]  
-sigma-20 [e:ga:m]
```

PSJ²
-lo
-Għiex-locx/Għiex-
-fotu-locx/fotu-
-Għixx-ux/Għixx-
-Għad-ix-xebha u l-ix-
-Dalli-Vinċżeek n-nadha
-Vixx-ix-Xien u -Vixx-
-degħi-ix/Siegħ
-Char-Exeġġ/Char-
-Vixx-dixx-tal, krida
Vixx
-Dalli-Vinċżejjx na lov
-Furm-Bażett/Furm-

XML

XML

- eXtensible Markup Language - značkovací (meta)jazyk
- pravidla, jak má vypadat správně vytvořený dokument
- snadné strojové zpracování a výměna informací
- konkrétní názvy značek určuje uživatel (standardy, vlastní)
- elementy: <značka>obsah</značka>
- bez obsahu lze <značka></značka> zkrátit na <značka/>
- atributy: <značka atribut="hodnota"/>



XML

- správné zanoření značek
- správně: `<a>text`
- špatně: `<a>text`
- speciální znaky se přepisují na entity (např. <)
 - `<`, `>`, `&`

Popis a kontrola obsahu

- **DTD** (Document Type Definition)
- seznam elementů a atributů a vztahy mezi nimi
- nekontroluje obsah
- <!ELEMENT vyznam (definice, priklad+)>
- <!ATTLIST vyznam cislo CDATA #REQUIRED>

Popis a kontrola obsahu

- **XML Schema** (XSD, XML Schema Definition)
- popis obsahu a struktury XML dokumentu, schéma samotné je XML dokument
- elementy, atributy, struktura
- možnost určit vlastní typy obsahu (např. opakující se adresa)
- kontrola obsahu (např. číselný rozsah, regulární výrazy, povolené hodnoty)

```
<xs:element name="definice">
  <xs:simpleType>
    <xs:restriction base="xs:string">
      <xsmaxLength value="120"/>
    </xs:restriction>
  </xs:simpleType>
</xs:element>
```

```
<xs:element name="definice">
  <xs:simpleType>
    <xs:restriction base="xs:string">
      <xs:maxLength value="120"/>
    </xs:restriction>
  </xs:simpleType>
</xs:element>
```

Standardy založené na XML

- web: XHTML
- matematika: MathML
- knihy: EPUB
- grafika: SVG
- dialogové systémy: VoiceXML
- metadata, sémantický web: RDF
- text: TEI
- lexikální data: LMF



XSL(T)

- eXtensible Stylesheet Language (Transformations)
- převod XML na jiné formáty
 - jiné XML značkování, text, HTML, LaTeX, PDF
- šablony pro části XML dokumentu
- postupné procházení dokumentu
- (funkcionální programovací jazyk)

```
<xsl:template match="definice">
  <b><xsl:value-of select="position()" />.</b>
  <i><xsl:value-of select="text()" />
</xsl:template>
```

funkcionální programovací jazyky

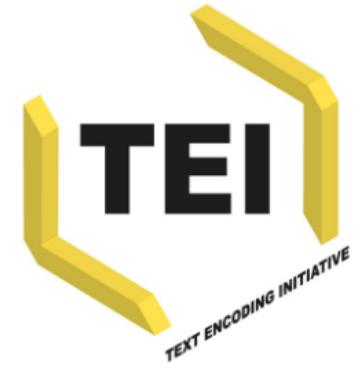
```
<xsl:template match="definice">
  <b><xsl:value-of select="position()"/>.</b>
  <i><xsl:value-of select="text()" />
</xsl:template>
```

TEI



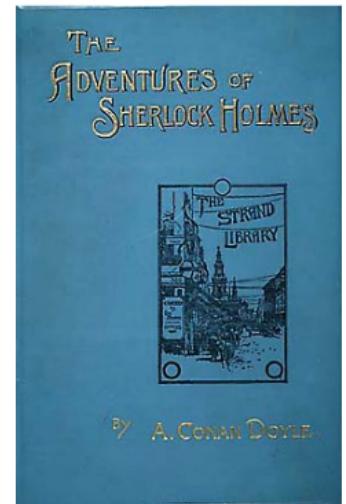
TEI

- Text Encoding Initiative
 - <http://www.tei-c.org/>
- *TEI Guidelines* (aktuálně verze 5 z roku 2007)
 - XML formát pro sémantický popis textových dokumentů
 - velký rozsah značek
 - *TEI Lite* - osekaná verze, "90 % potřeb 90 % uživatelů"
 - romány, poezie, divadelní hry, dokumentace, slovníky, korpusy, grafy, rukopisy, zarovnání, odkazy, změny textu, notové zápisy...
 - nástroje - sada XSLT pro převod na LaTeX, docx, EPUB, HTML



Knihy

```
<text>
  <front>
    <head rend="italic">Adventures of Sherlock Holmes</head>
    <docTitle>
      <titlePart>Adventure II. —</titlePart>
      <titlePart>The Red-Headed League</titlePart>
    </docTitle>
    <byline>By A. Conan Doyle.</byline>
  </front>
  <body>
    <p>I had called upon my friend, Mr. Sherlock Holmes, one day
      in the autumn of last year and found him in deep conversation
      with a very stout, florid-faced, elderly gentleman with fiery red hair ...
    </p>
  </body>
</text>
```



Divadelní hry

```
<div type="Act" n="I">
  <head>ACT I</head>
  <div type="Scene" n="1">
    <head>SCENE I</head>
    <stage rend="italic"> Enter Barnardo and Francisco, two
    Sentinels, at several doors</stage>
    <sp>
      <speaker>Barn</speaker>
      <l part="Y">Who's there?</l>
    </sp>
    <sp>
      <speaker>Fran</speaker>
      <l>Nay, answer me. Stand and unfold yourself.</l>
    </sp>
```



Značkování

<q>My dear <rs type="person">Mr. Bennet</rs>, </q>
said his lady to him one day, <q>have you heard that <rs
type="place">Netherfield Park</rs> is let at last?</q>

<s n="1">
 <w ana="#NP0">Marley</w>
 <w ana="#VBD">was</w>
 <w ana="#AJ0">dead</w>
 <pc>:</pc>
 <w ana="#TOO">to</w>
 <w ana="#VBB">begin</w>
 <w ana="#PRP">with</w>
 <pc>. </pc>
</s>



Slovníky, podoba hesla

```
<entry>
  <form>
    <orth>competitor</orth>
    <hyph>com|peti|tor</hyph>
    <pron>k@m"petit@(r)</pron>
  </form>
  <gramGrp>
    <pos>n</pos>
  </gramGrp>
  <def>person who competes.</def>
</entry>
```

Slovníky, významy

<sense n="1">
 <gramGrp>
 <subc>VP6A</subc>
 </gramGrp>
 <def>turn (a ship) on one side for cleaning, repairing, etc.</def>
</sense>
<sense n="2">
 <gramGrp>
 <subc>VP6A</subc>
 <subc>VP2A</subc>
 </gramGrp>
 <def>(cause to) tilt, lean over to one side.</def>
</sense>



Slovníky, překlady

```
<form>
    <orth>dresser</orth>
</form>
<sense>
    <usg type="dom">Theat</usg>
    <cit type="translation" xml:lang="fr">
        <quote>habilleur</quote>
        <gramGrp>
            <gen>m</gen>
        </gramGrp>
    </cit>
```

Slovníky, příklady

```
<cit type="example">
    <quote>the multiplex eye of the fly.</quote>
</cit>
```

```
<cit type="example">
    <quote>elle était horrifiée par la dépense</quote>
    <cit type="translation" xml:lang="en">
        <quote>she was horrified at the expense.</quote>
    </cit>
</cit>
```

Slovníky, příznaky

<form>

 <orth>colour</orth>

 <form>

 <usg type="geo">U.S.</usg>

 <orth>color</orth>

 </form>

</form>

<usg type="syn">aube de roue</usg>

<usg type="dom">Constr</usg>



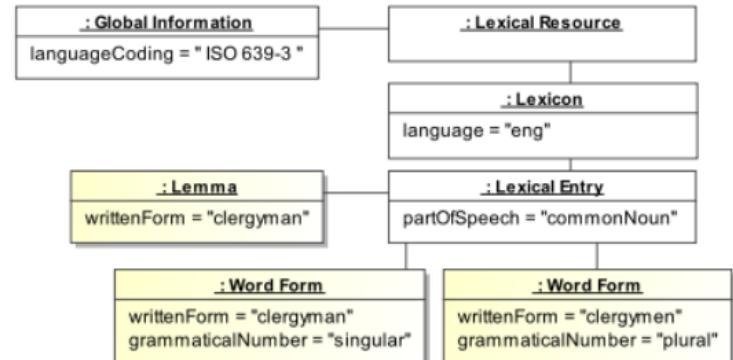
TEI, projekty

- Oxford Text Archive
- British National Corpus
- FreeDict
- Cambridge University Press
- Chinese Buddhist Electronic Text Association
- Deutsches Textarchiv
- Europeana Regia

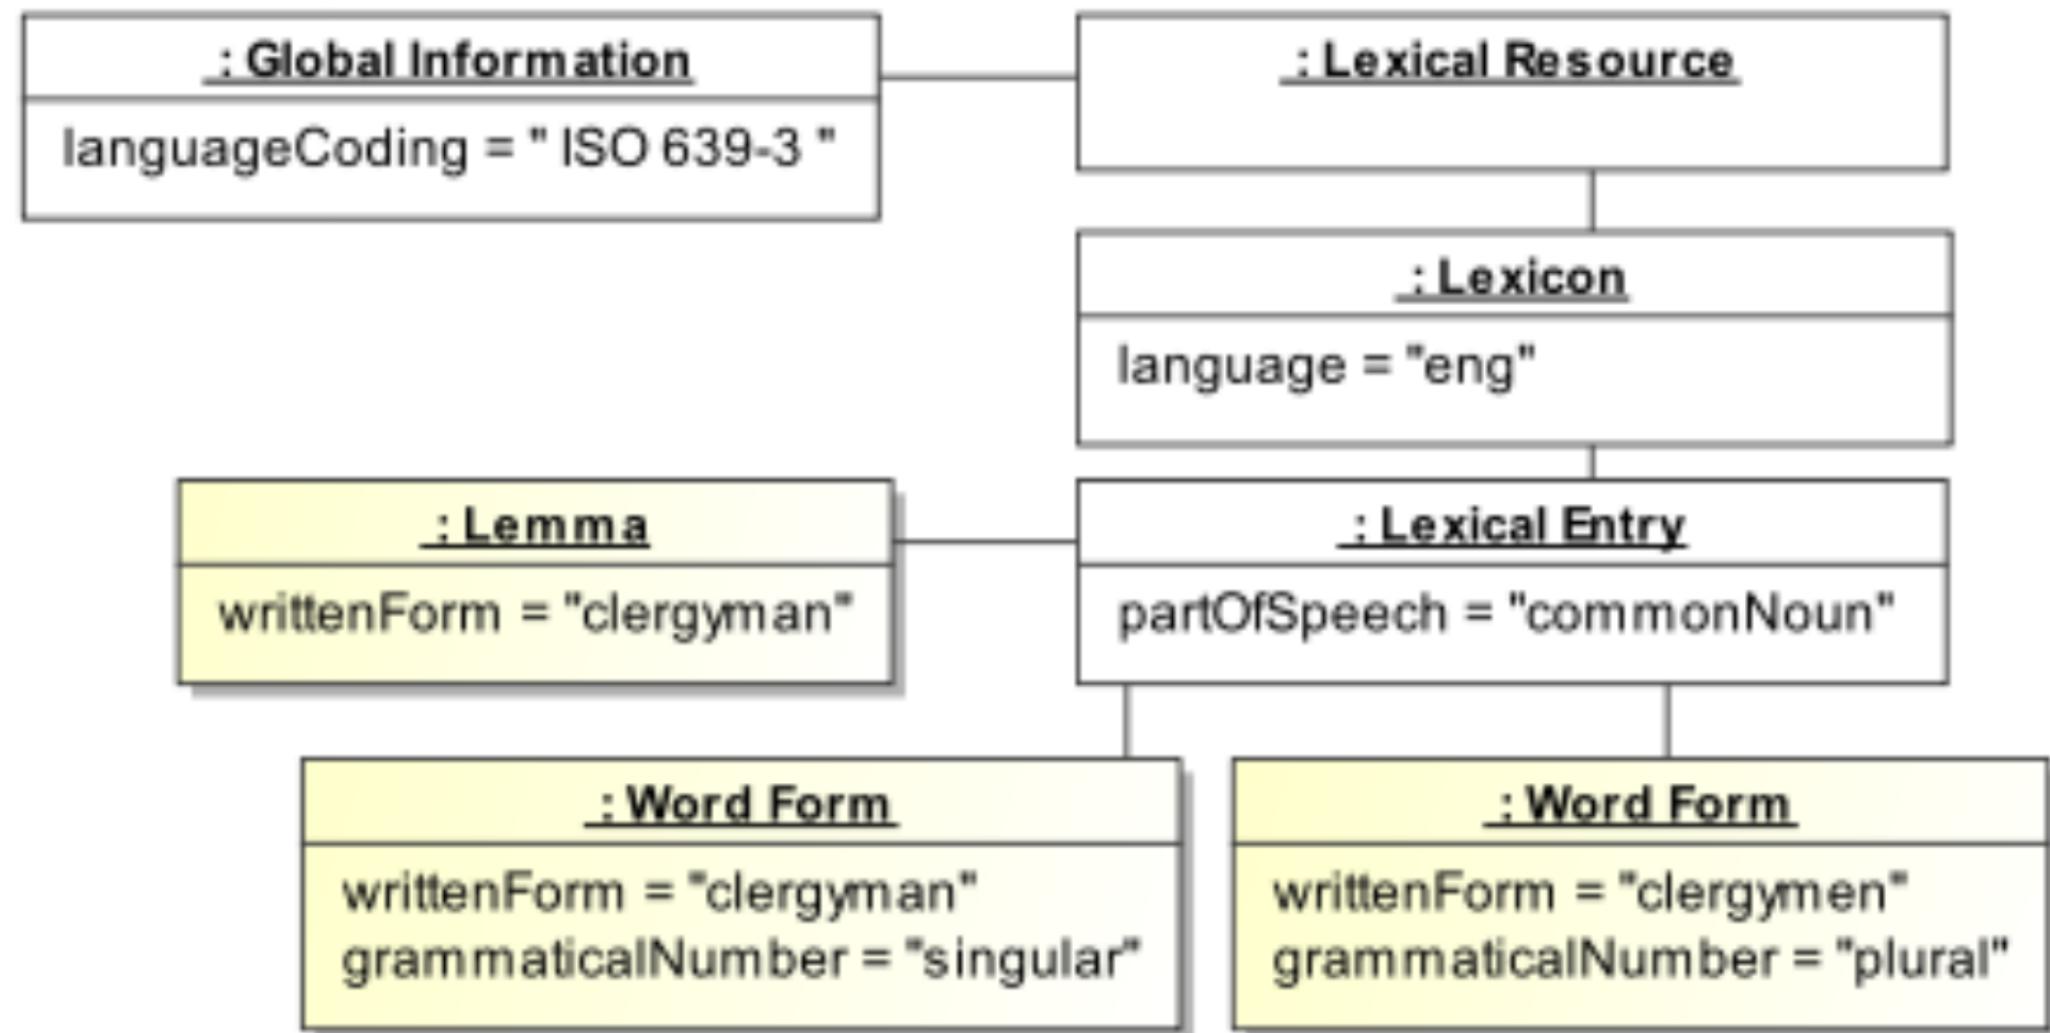
LME

LMF

- Lexical Markup Framework
 - <http://www.lexicalmarkupframework.org/>
- ISO-24613:2008
- jednotný model pro tvorbu lexikálních zdrojů
- důraz na strojové zpracování a rozšiřitelnost
 - UML diagram pro lexikon
- jádro se základními informacemi + rozšíření pro různé oblasti (morfologie, syntax, sémantika...)



ka...)



Slovník

```
<Lexicon>
  <feat att="language" val="eng"/>
  <LexicalEntry>
    <feat att="partOfSpeech" val="commonNoun"/>
    <Lemma>
      <feat att="writtenForm" val="clergyman"/>
    </Lemma>
    <WordForm>
      <feat att="writtenForm" val="clergyman"/>
      <feat att="grammaticalNumber" val="singular"/>
    </WordForm>
    <WordForm>
      <feat att="writtenForm" val="clergymen"/>
      <feat att="grammaticalNumber" val="plural"/>
    </WordForm>
  </LexicalEntry>
</Lexicon>
```

Významy

<Lexicon>

```
<feat att="language" val="fra"/>
<LexicalEntry>
  <feat att="partOfSpeech" val="adjective"/>
  <Lemma>
    <feat att="writtenForm" val="actif"/>
  </Lemma>
  <Sense id="S1">
    <feat att="definition" val="Qui agit ou implique une activité"/>
  </Sense>
  <Sense id="S2">
    <feat att="definition" val="Propre à exprimer que le sujet est
    considéré comme agissant"/>
    <feat att="domain"  val="grammaire"/>
  </Sense>
</LexicalEntry>
```

WordnetLMF



```
<!DOCTYPE LexicalResource SYSTEM "kyoto_wn.dtd">
<GlobalInformation label="Wordnet entries using Kyoto-LMF">
<Lexicon languageCoding="ISO 639-3" label="English Wordnet 3.0"
language="eng" owner="Princeton" version="3.0">

<LexicalEntry id="LE_footprint">
  <Lemma writtenForm="footprint" partOfSpeech="n" />
  <Sense id="S_footprint_1" synset="eng-30-06645039-n">
    <MonolingualExternalRefs>
      <MonolingualExternalRef
        externalSystem="Wordnet3.0"
        externalReference="footprint&#37;1:10:00::" />
    </MonolingualExternalRefs>
  </Sense>
</LexicalEntry>

<LexicalEntry id="LE_footmark">
  <Lemma writtenForm="footmark" partOfSpeech="n"/>
  <Sense id="S_footmark_1" synset="eng-30-06645039-n">
    <MonolingualExternalRefs>
      <MonolingualExternalRef
        externalSystem="Wordnet3.0"
        externalReference="footmark&#37;1:10:00::" />
    </MonolingualExternalRefs>
  </Sense>
</LexicalEntry>
```



```
<Synset id="eng-30-06645039-n" baseConcept="1">
  <Definition gloss="mark of a foot or shoe on a surface">
    <Statement example="the police made casts of the footprints
      in the soft earth outside the window" />
  </Definition>
  <SynsetRelations>
    <!-- (mark, print): -->
    <SynsetRelation target="eng-30-06798750-n" relType="has_hyperonym" >
      <Meta author="AH" date="2008-07-01" source="Wordnet3.0"
        status="yes" confidenceScore="1.0" />
    </SynsetRelation>
    <!-- (footprint_evidence): -->
    <SynsetRelation target="eng-30-06645266-n" relType="has_hyponym" >
      <Meta author="AH" date="2008-07-01" source="eng-Wordnet3.0"
        status="yes" confidenceScore="1.0" />
    </SynsetRelation>
  </SynsetRelations>
  <MonolingualExternalRefs>
    <MonolingualExternalRef
      externalSystem="SUMO"
      externalReference="superficialPart" relType="at"/>
  </MonolingualExternalRefs>
</Synset>
```

Linked Data

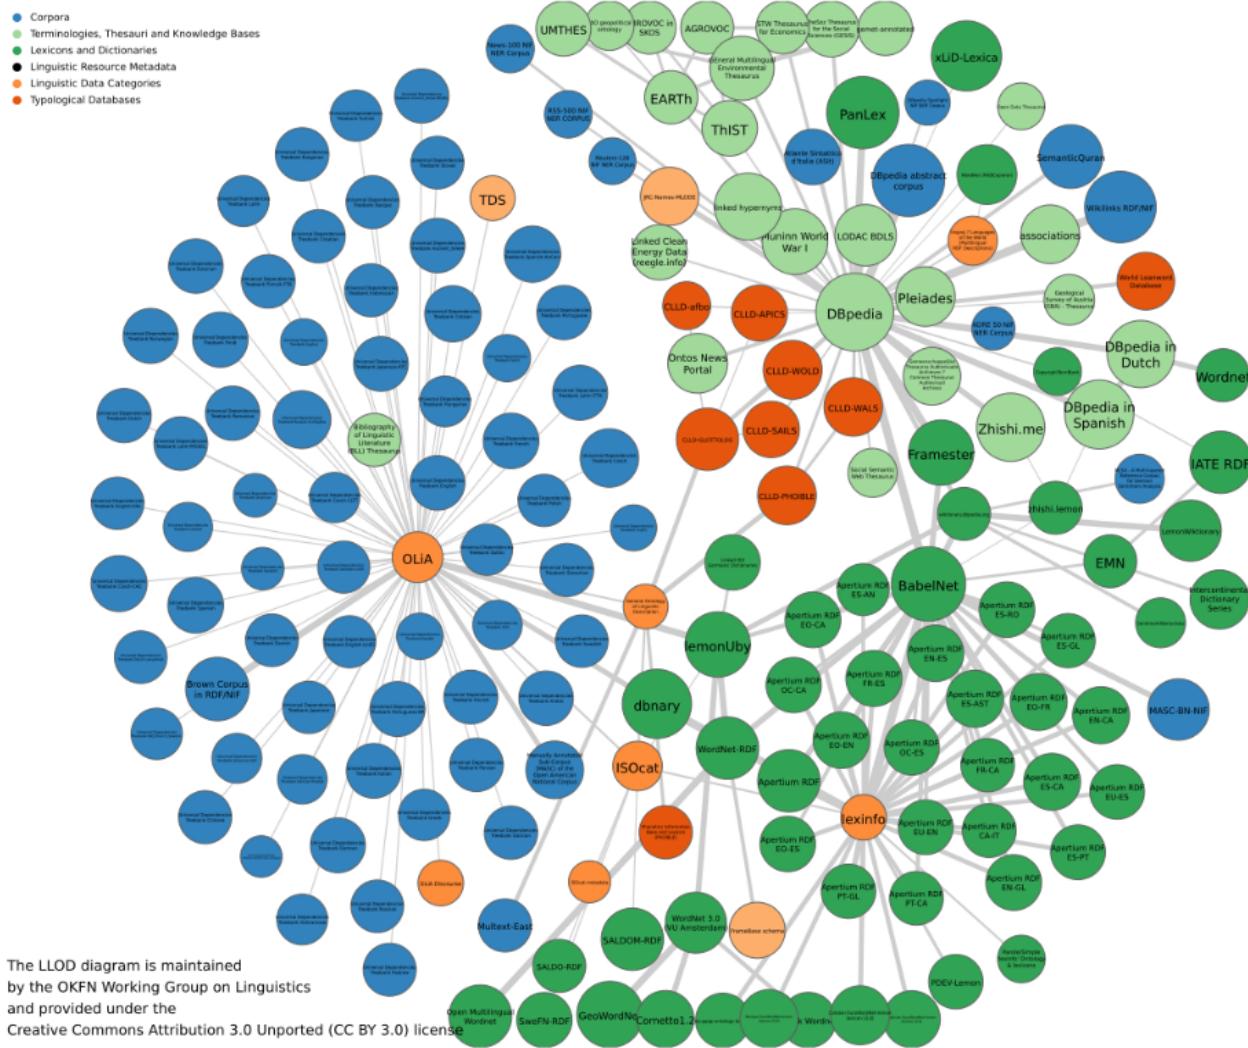
Linked (Open) Data

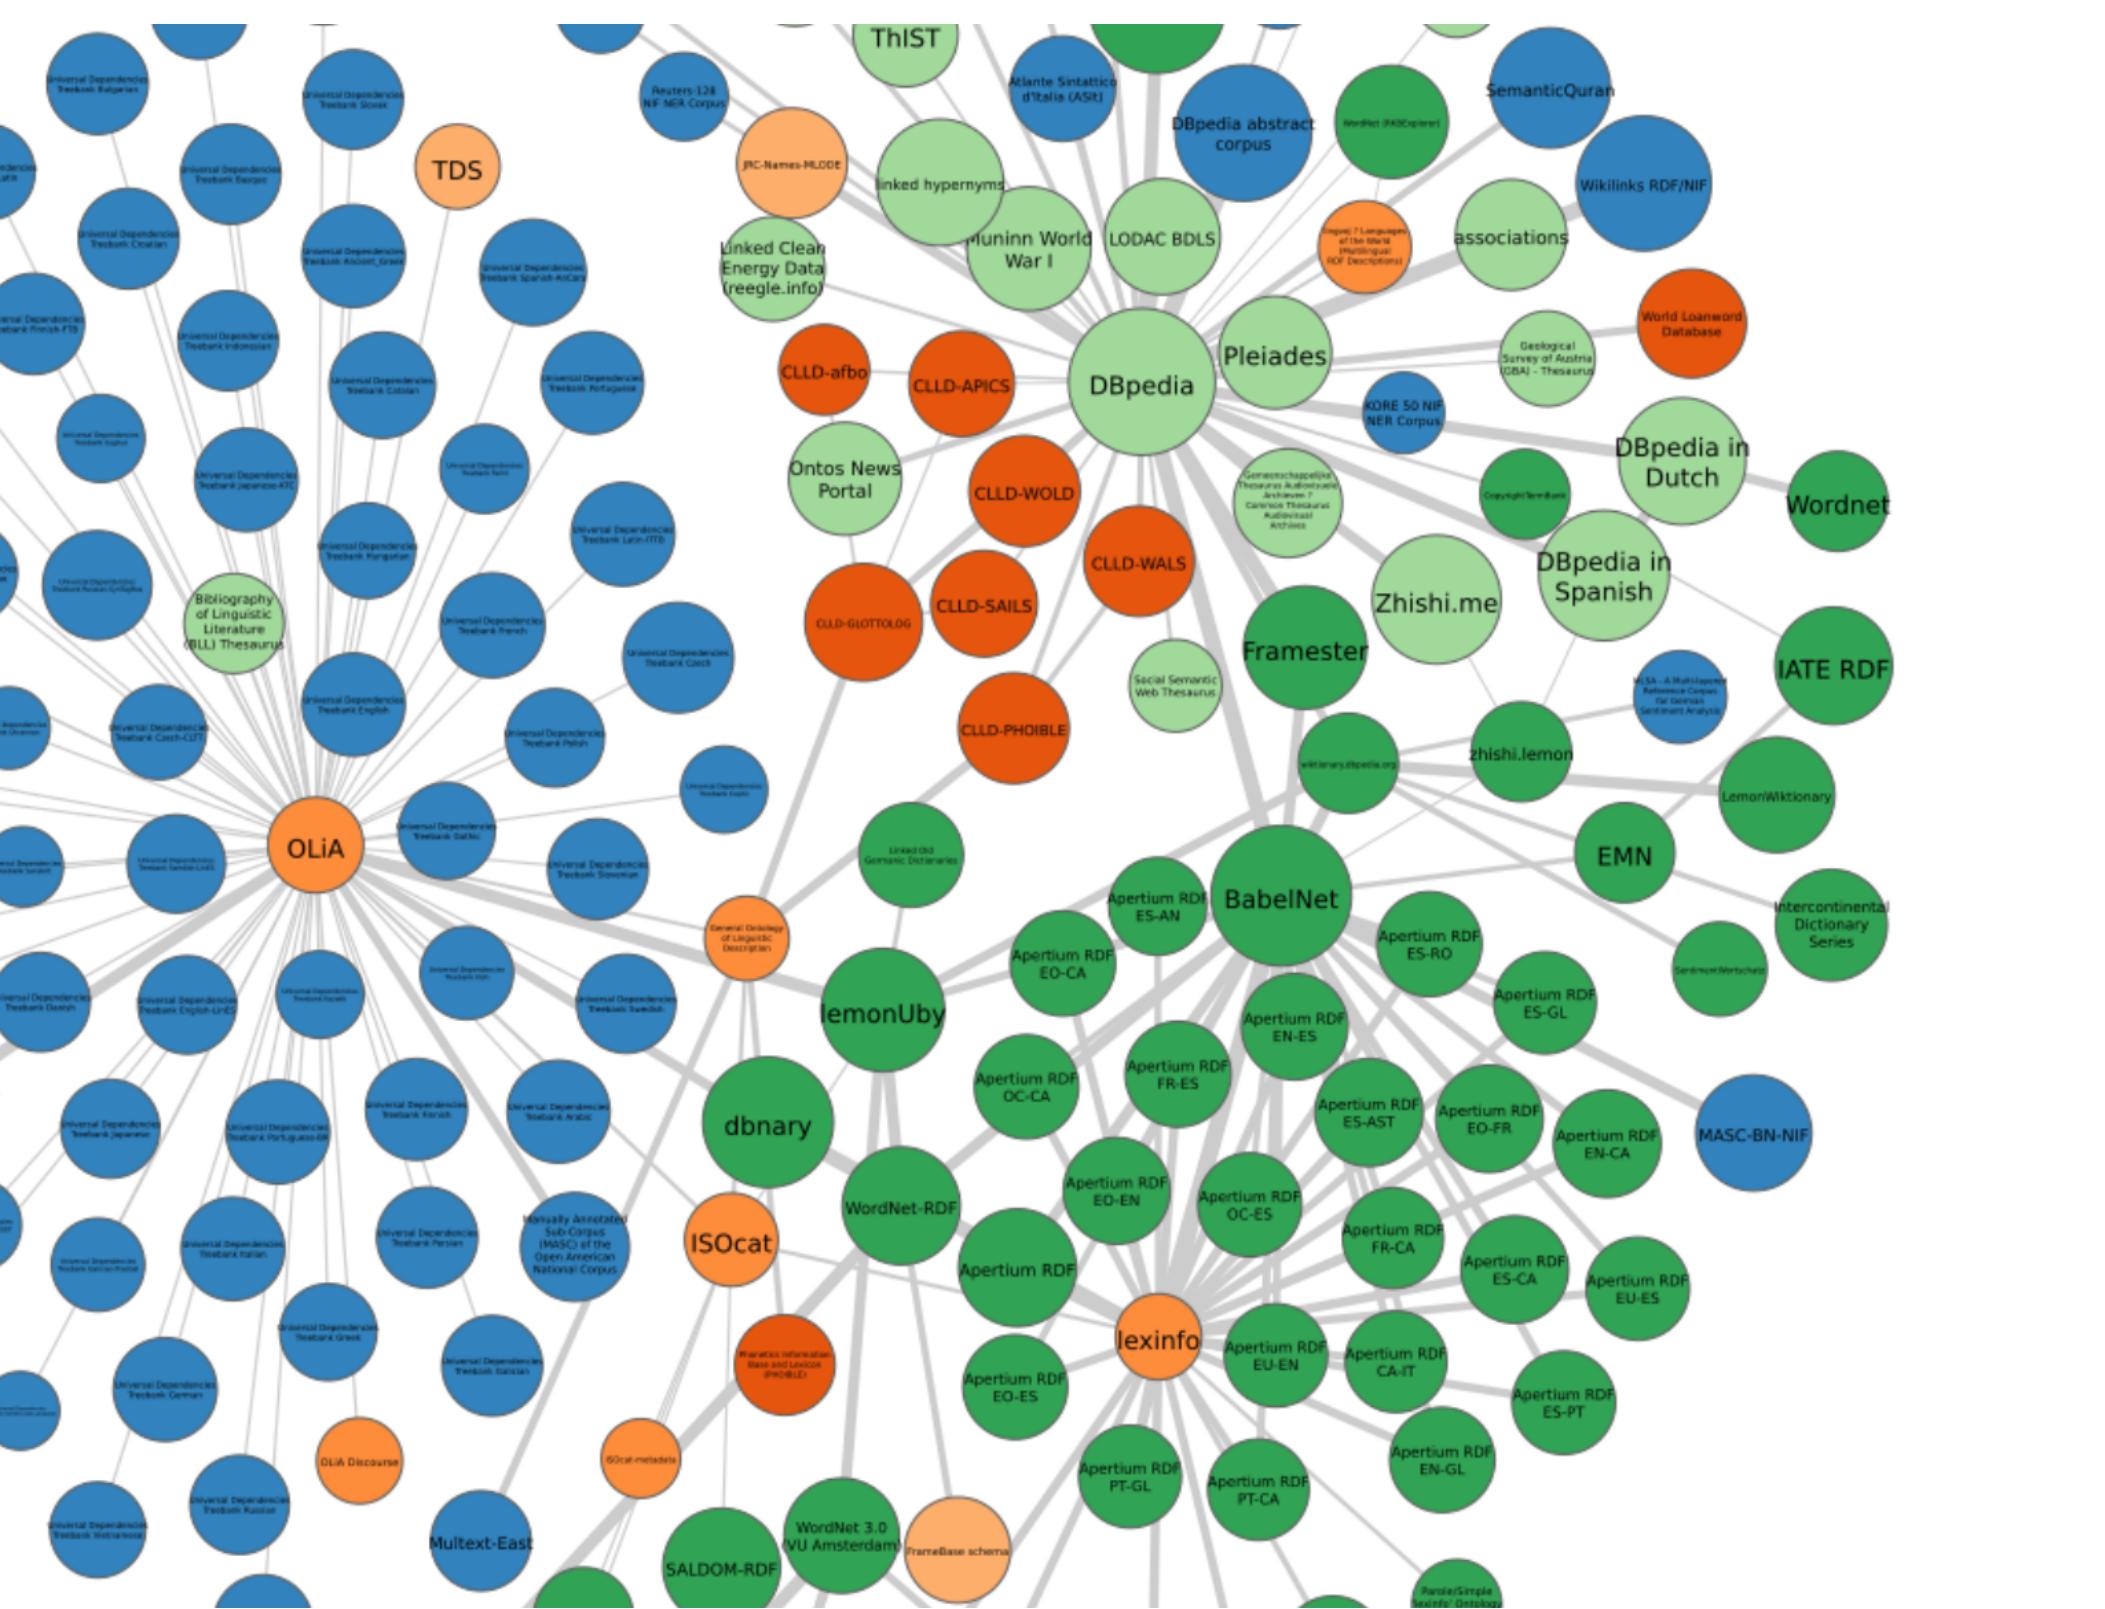
- otevřené licence (často Creative Commons)
- standardní formáty (XML, RDF, JSON)

Linked (Open) Data

- otevřené licence (často Creative Commons)
- standardní formáty (XML, RDF, JSON)
- každý záznam má jedinečné URI
- URI v prohlížeči zobrazí záznam
- odkazy na další zdroje
- výhody
 - spojování zdrojů
 - volné použití
 - přenositelnost
 - existující nástroje
 - aktualizace

<http://linguistic-lod.org>





Ukázka



SSČ

```
<root>
  <h>lov</h>
  <gram>-u m</gram>
  <sens>
    <num>1</num>
    <exp>lovení zvěře a ryb</exp>
    <exm><t>lov koroptví</t></exm>
    <exm><t>lov na zajíce</t></exm>
    <exm><t>liška vyšla na lov</t></exm>
  </sens>
  <sens>
    <num>2</num>
    <ref>úlovek<refcateg>syno</refcateg></ref>
    <ref>kořist<refcateg>syno</refcateg></ref>
    <exm><t>mít bohatý lov</t></exm>
  </sens>
</root>
```

přepis

<h>lov</h>
<norm>-u</norm>
<small>m.</small>
<small>(</small>
<small>6. j.</small>
<norm>-u)</norm>
<bold>1.</bold>
<ital>stíhání a zmocňování se zvěře</ital>
<ital>(</ital>
<ital>nejč. odstřelem); chytání ryb:</ital>
<norm>
l. jelenů, divokých kachen, velryb; l. lososů; l. perel; doba
lovu; uspořádat l. na medvědy; vyjet na l.; právo lovů; l.
odstřelem, chytáním, lapáním; l. lesní, polní, vodní;
hromadný l.
</norm>

<h>

<Cil>lov</Cil>

<Heslo>lov,</Heslo>

<Tvar>-u</Tvar>

<Gram>m.</Gram>

<Vyzn>honba n. lapání zvěře n. chytání ryb.</Vyzn>

<Dokl>Vrchnost na lov byla.</Dokl>

<Pram>Něm.</Pram>

<Sep>D</Sep>

<Char>Expr.</Char>

<Vyzn>chytání, krádež, získávání, shánění čehokoliv.</Vyzn>

<Dokl>Netopýr na lov kmitl se kolem.</Dokl>

<Pram>Baar.</Pram>

různé XML formáty, stejný vzhled (XSLT)

SSJC Slovník spisovného jazyka českého

lov

-u m. (6. j. -u)

1. *stíhání a zmocňování se zvěře (nejč. odstřelem); chytání ryb:* l. jelenů, divokých kachen, velryb; l. lososů; l. perel; doba lovů; uspořádat l. na medvědy; vyjet na l.; právo lovů; l. odstřelem, chytáním, lapáním; l. lesní, polní, vodní; hromadný l. *hon*; liška vyšla na l.; lovů zdar! (*lovecký pozdrav*)

2. *expr. chytání, shánění čehokoliv, vůbec získávání, při kterém se uplatní obratnost a náhoda:* l. vzácného hmyzu; sběratelé se vydali na l. lidových písni; policie podnikla l. na zloděje; *expr.* to je l.! *šťastný nález, výhodná koupě ap.*

3. *výsledek lovů; úlovek, kořist:* vrátit se s bohatým lovem *s ulovenou zvěří ap.*, přen. *expr. s věcmi získanými obratností n. šťastnou náhodou*

SSC Slovník spisovné češtiny

lov

-u m

1. *lovení zvěře a ryb* lov koroptví, lov na zajíce, liška vyšla na lov,

2. *úlovek (syno) kořist (syno)* mít bohatý lov,
