

Služby spracovania textu vytvorené na FIIT STU

OK



PeWe@FIIT
personalized web group

11.11.2014



SK Lemmatizátor

- <http://text.fiit.stuba.sk/lemmatizer/>
- Lematizácia slovenského textu
- Rýchla
 - Plain-text
 - Najpravdepodobnejšie lemmy
- Úplna
 - XML alebo JSON
 - Všetky lemmy pre každý pojem na vstupe

URL: `http://text.fiit.stuba.sk:8080/lematizer
/services/lemmatizer/lemmatize/fast`

Method: POST

Headers: Content-Type: text/plain

Data: Už niekoľko rokov patrí Slovensko medzi krajiny
s najvyšším počtom áut vyrobených na tisíc
obyvateľov.

Response

Data: už niekoľko rok patriť slovensko medzi krajina
s vysoký počet auto vyrobený na tisíc obyvateľ

URL: http://text.fiit.stuba.sk:8080/lematizer
/services/lemmatizer/lemmatize/full

Method: POST

Headers: Content-Type: text/plain

Data: Mám psa.

Response

Data: <?xml version="1.0" encoding="UTF-8" standalone="yes"?>
<customLemmasHolders>
 <customLemmasHolder>
 <form>mám</form>
 <lemmas>
 <lema>mama</lema><rank>0</rank>
 </lemmas>
 <lemmas>
 <lema>mat'</lema><rank>0</rank>
 </lemmas>
 <lemmas>
 <lema>mámit'</lema><rank>0</rank>
 </lemmas>
 </customLemmasHolder>
 <customLemmasHolder>
 ...podobne pes ...
 </customLemmasHolder>
</customLemmasHolders>

Morpholyzer

- <http://morpholyzer.fiit.stuba.sk:8080/PosTagger/>
- Identifikácia slovných druhov v slovenskom texte
- Všetky, prípustné, najpravdepodobnejšia
- *Prvá ľudská sonda zacielená na kométu sa blíži k cieľu.*

Európa	Európa Podstatné meno substant. par. ženský r. singulár nominatív	Európa Podstatné meno substant. par. ženský r. singulár vokatív	
chce	chcieť Sloveso prézent nedokonavý v. singulár tretia afirmácia		
pristát'	pristát' Sloveso infinitív dokonavý v. afirmácia		
na	na Predložka vokalizovaná akuzatív	na Predložka vokalizovaná lokál	na Citoslovce

kométe	kométa Podstatné meno substant. par. ženský r. singulár datív	kométa Podstatné meno substant. par. ženský r. singulár lokál
Zobudia	zobudiť Sloveso prézent dokonavý v. plurál tretia afirmácia	
sondu	sonda Podstatné meno substant. par. ženský r. singulár akuzatív	

Metallurgy

- <http://metallurgyapi.eu/>
- Získavanie metadát k textom
- Obsah
 - Text zo zadanej web stránky
- Tokeny
 - Rozdelí text na slová a tokenizuje
- Kľúčove slová
 - top slová v dokumente (TF/IDF)
 - možnosť zadať väčší korpus dokumentov naraz


```
http://metallurgyapi.eu/content.json?url=http%3A%2F%2Fnitra.sme.sk%2Fc%2F6588534%2Fnajstarsiu-rotundu-v-strednej-europe-uvidi-verejnost.html
```

```
{  
  success: true,  
  content: " Pamiatka je najstaršou stojacou rotundou  
              nielen na Slovensku, ale zrejme aj ... "  
}
```

<http://metallurgyapi.eu/content.json?url=http%3A%2F%2Fnitra.sme.sk%2Fc%2F6588534%2Fnajstarsiu-rotundu-v-strednej-europe-uvidi-verejnost.html>

```
{  
  success: true,  
  tokens: [  
    "pamiatka",  
    "je",  
    "najstaršia",  
    "stojac",  
    "rotund",  
    "nielen",  
    "na",  
    "slovensku",  
    "al",  
    "zrejm",  
    "aj",  
    "v",  
    ...  
  ]  
}
```

<http://metallurgyapi.eu/keywords.json?url=http%3A%2F%2Ftechcrunch.com%2F2012%2F11%2F09%2Fcan-social-media-influence-really-be-measured%2F>

```
{  
  success: true,  
  language: "en",  
  category: "Agriculture",  
  keywords: [  
    {  
      keyword: "algorithm",  
      rating: 2.09635,  
      idf: 4.79165  
    },  
    {  
      keyword: "score",  
      rating: 1.03667,  
      idf: 1.71587  
    },  
  ]  
}
```

CollEx

- <http://metallurgyapi.eu:8080/collex/>
- Extrakcia kolokácií v slovenskom jazyku
- Rozdelenie textu na vety
- Identifikácia kolokácií pre dvojice a trojice susediacich slov
- „*Zajtra ráno bude pekne.*“

```
<sentences>
  <sentence>
    <bigrams>
      <bigram words="zajtra ráno">
        <score name="PmiScore" value="4.114" collocation="true"/>
      </bigram>
      <bigram words="ráno bude">
        <score name="PmiScore" value="0.325" collocation="false"/>
      </bigram>
      <bigram words="bude pekne">
        <score name="PmiScore" value="0.728" collocation="false"/>
      </bigram>
    </bigrams>
    <trigrams>
      <trigram words="zajtra ráno bude">
        <score name="PmiScore" value="2.533" collocation="true"/>
      </trigram>
      <trigram words="ráno bude pekne">
        <score name="PmiScore" value="-0.080" collocation="false"/>
      </trigram>
    </trigrams>
  </sentence>
</sentences>
```

NER

- <http://mus.fiit.stuba.sk/>
- Extrakcia pomenovaných entít zo slovenských textov v prirodzenom jazyku
- Vstup
 - Text
 - url
- [mus.fiit.stuba.sk/ner/?type=words&content=Zdeno Chára oslávil 500. zápas v drese Bostonu v NHL asistenciou a víťazstvom 3:2 v Ottawe](http://mus.fiit.stuba.sk/ner/?type=words&content=Zdeno%20Ch%C3%A1ra%20osl%C3%A1vil%20500.%20z%C3%A1pas%20v%20drese%20Bostonu%20v%20NHL%20asistenciou%20a%20v%C3%ADtaazstvom%203%3A2%20v%20Ottawe)

```
[  
  {  
    real_name: "Zdeno Chára",  
    name: "Zdeno Chára",  
    typ: "P",  
    start_index: 2,  
    end_index: 3  
  },  
  {  
    real_name: "Boston",  
    name: "Bostonu",  
    typ: "L",  
    start_index: 10,  
    end_index: 10  
  },  
  {  
    real_name: "NHL",  
    name: "NHL",  
    typ: "O",  
    start_index: 12,  
    end_index: 12  
  },  
  ...  
]
```

