


# LeXmart

## A Smart Tool for Lexicographers

A. Simões, A. Salgado, R. Costa & J. J. Almeida



# Outline

Motivation

LeXmart Birth

LeXmart

- Architecture

- End-User Tools

- Lexicographic Support Tools

- Content Management System

- RESTful API

Conclusions

# Motivation

- ▶ Academy of Sciences Portuguese dictionary
- ▶ Published in paper format (2001)
- ▶ A new goal for 2019–202?: publish an updated version online
- ▶ The original dictionary was only available in PDF format
- ▶ A conversion to a computer readable format was required
- ▶ Need for a tool to allow concurrent edition of the dictionary

# LeXmart Birth

- ▶ Develop a process to convert the PDF format into XML (TEI)
- ▶ Split the dictionary by entries, in different files
- ▶ Import entries into a database that:
  - ▶ should be aware of XML structure
  - ▶ should be able to query entries using XML structure
  - ▶ allow quick editing on XML aware IDEs
- ▶ eXist-DB was chosen  
(easy to integrate with Oxygen XML Editor)
- ▶ A set of small tools to assess current dictionary status:
  - ▶ validate entries
  - ▶ edit entries
  - ▶ show reports on entry classifications/grammar information

# LeXmart

smart lexicography

<http://lexmart.eu>

- ▶ A collection over eXist-DB for the dictionary:
  - ▶ Each dictionary entry is an individual XML file
  - ▶ Entries are codified using the TEI Dictionary module
  - ▶ TEI headers are not being currently stored

- ▶ A collection over eXist-DB for the dictionary:
  - ▶ Each dictionary entry is an individual XML file
  - ▶ Entries are codified using the TEI Dictionary module
  - ▶ TEI headers are not being currently stored
- ▶ A collection for the application:
  - ▶ Development in XQuery 3.0 and XPath 3.0
  - ▶ TEI embedded into HTML directly, using CSS

- ▶ A collection over eXist-DB for the dictionary:
  - ▶ Each dictionary entry is an individual XML file
  - ▶ Entries are codified using the TEI Dictionary module
  - ▶ TEI headers are not being currently stored
- ▶ A collection for the application:
  - ▶ Development in XQuery 3.0 and XPath 3.0
  - ▶ TEI embedded into HTML directly, using CSS
- ▶ A collection for the CMS pages



# End-User Tools

## Headword search

- ▶ The typical use of a dictionary
- ▶ Quite efficient, querying the orth TEI elements.

Dicionário da Academia das Ciências de Lisboa

Páginas ▾ palavra

Condensado/Expandido

Estado: **Importado**

**elefante**

*n. m., f.*

- 1.** class. **Zool.** Mamífero, herbívoro, de grande porte, da ordem dos proboscídeos, família dos elefantídeos (*E. africanus*, Falc.), (*Elefas*, Lin.) e (*E. maximus*, Lin.), caracterizado pelos incisivos superiores muito desenvolvidos, habitualmente denominados presas ou defesas, e por uma tromba, ou proboscis, preênsil e móvel, que utiliza para respirar, colher alimentos, aspirar água... *O elefante africano é maior que o elefante asiático. A caça ao elefante está proibida por lei. O mamute é uma variedade de elefante fóssil.*  
*«Os elefantes afastam-se por desistência: por terem perdido o rasto das fêmeas e das crias e a memória das paisagens e dos rios.»* (J. DE MELO, *Gente Feliz*, 447)  
**Caça ao +; tromba de +.**
- 2.** registar **Deprec.** registar **Inf.** Pessoa muito gorda e de andar pesado.
- 3.**
  - elefante branco**  
coisa, objecto, negócio... de conservação muito dispendiosa, sendo o seu rendimento de pouca ou nenhuma utilidade. *Aquela empresa é o elefante branco do Governo.*
  - ter memória de elefante**  
ter uma excelente capacidade de reter lembranças; de guardar no pensamento.
  - ter tromba de elefante**  
andar habitualmente trombudo, carrancudo.  
(Do lat. *elephas*, *-antis* < gr. *ἐλέφας*)

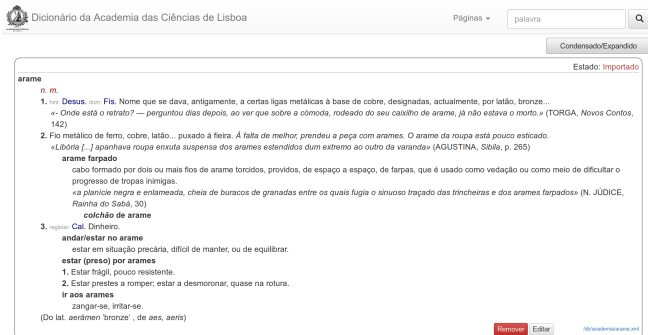
[ribsciencia/elefante.xml](http://ribsciencia/elefante.xml)

search by “elefante” (*elephant*)

# End-User Tools

## Reverse search

- ▶ not possible on paper dictionaries
- ▶ allow querying by the definition
- ▶ queries all entry definition information (slower)



Dicionário da Academia das Ciências de Lisboa

Páginas ▾ palavra

Condensado/Expandido

Estado: **Importado**

**arame**

*n. m.*

- <sup>1.</sup> <sup>1.</sup> **Desus.** <sup>2.</sup> **Fis.** Nome que se dava, antigamente, a certas ligas metálicas à base de cobre, designadas, actualmente, por latão, bronze...  
«- Onde está o retrato? — perguntou dias depois, ao ver que sobre a cómoda, rodeado do seu calção de arame, já não estava o morto.» (TORGA, *Novos Contos*, 142)
- <sup>2.</sup> Fio metálico de ferro, cobre, latão... puxado à feira. *A falta de melhor, prendeu a peça com arames. O arame da roupa está pouco esticado.*  
«Libéria [...] apanhava roupa enxuta suspensa dos arames estendidos dum extremo ao outro da varanda» (AGUSTINA, *Sibila*, p. 265)

**arame farpado**  
cabo formado por dois ou mais fios de arame torcidos, providos, de espaço a espaço, de farpas, que é usado como vedação ou como meio de dificultar o progresso de tropas inimigas.  
«a planície negra e enlameada, cheia de buracos de granadas entre os quais fugia o sinuoso traçado das trincheiras e dos arames farpados» (N. JÚDICE, *Rainha do Sabão*, 30)

**calção de arame**

- <sup>3.</sup> <sup>1.</sup> **registro:** Cal. Dinheiro.  
**andar/estar no arame**  
estar em situação precária, difícil de manter, ou de equilibrar.  
**estar (preso) por arames**  
1. Estar frágil, pouco resistente.  
2. Estar prestes a romper; estar a desmoronar, quase na rotura.

**ir aos arames**  
zangar-se, irritar-se.  
(Do lat. *aerāmen* 'brnze', de *aes*, *aeris*)

[/s/academiadasciencias.pt](#)

search by “fio ferro” (*iron thread* → *wire*)

# Lexicographic Support Tools

## Entry editor

- ▶ Based on Xonomy XML editor (JavaScript based)
- ▶ Entries as fetched and saved directly from/into eXist-DB
- ▶ Configurable accordingly with the XML standard being used
- ▶ Contextual menus



The screenshot displays the Xonomy XML editor interface. At the top, there are buttons for 'Alterar modo' and 'Guardar'. Below, the XML structure is shown with a tree view on the left and the XML content in the main area. The entry is for 'elefante' and includes various XML tags and attributes.

```
entry xsi:noNamespaceSchemaLocation="http://per-fide.d1.uninho.pt:8080/exist/rest/db/schemas/academia-new.xsd">

meta status imported



form



- orth elefante
- pron ilif'èti
- group
  - granGrp n. n., f.
  - sense n 1
    - usgDom Zool.
    - def

Manífero, herbívoro, de grande porte, da ordem dos proboscídeos, família dos elefantídeos. mentioned author Falc. E. africanus, mentioned author Lin. Elefas e mentioned author Lin. E. maximus, caracterizado pelos incisivos superiores muito desenvolvidos, habitualmente denominados presas ou defesas, e por uma tromba, ou proboscis, preñsil e móvel, que utiliza para respirar, colher alimentos, aspirar água...



quote type example



O elefante africano é maior que o elefante asiático. A caça ao elefante está proibida por lei. O mamute é uma variedade de elefante fóssil.



quote type example



Caça ao +; dente, tromba de +.

```

# Lexicographic Support Tools

## Entry editor

Alterar modo    Guardar

entry    xsi:noNamespaceSchemaLocation    http://per-fide.di.uminho.pt:8

meta    status    imported

form

orth    elefante

pron    ilif'eti

group

- Adicionar novo grupo gramatical
- Adicionar Combinatória Independente
- Adicionar nota
- Remover este grupo
- Marcar como apenas digital

de grande porte, da ordem dos probi

loned    author    Falc.    E.

ned    author    Lin.    Elefas e    men

supriene quite desculpides habitualmente desculpide:

# Lexicographic Support Tools

Entry creation and deletion

- ▶ When viewing an entry, lexicographer can delete it (after confirmation)
- ▶ Adding a new entry will require the headword and:
  - ▶ guarantee no other entry with the same headword
  - ▶ create a stub XML document, adding it to the database
  - ▶ open the editor with that document

# Lexicographic Support Tools

## Meta Annotation

- ▶ Allow lexicographers to annotate entries and/or senses:
  - ▶ imported → directly imported from the paper dictionary
  - ▶ new → a new entry, created directly using LeXmart
  - ▶ edited → the entry was edited, but not yet considered final
  - ▶ revised → the entry can be made available publicly)

(together with this information, a timestamp is recorded)
- ▶ Annotate entries as to be used only on digital version

# Lexicographic Support Tools

## Filters and Statistics

- ▶ Entries have diverse type of metainformation:
  - ▶ grammatical information
  - ▶ geographic source
  - ▶ register type
  - ▶ domain knowledge

# Lexicographic Support Tools

## Filters and Statistics

- ▶ Entries have diverse type of metainformation:
  - ▶ grammatical information
  - ▶ geographic source
  - ▶ register type
  - ▶ domain knowledge
- ▶ Filtering allows reports for specific kinds:
  - ▶ a list of terms from a specific geographic location
  - ▶ terms from a specific knowledge area
  - ▶ etc.




# Lexicographic Support Tools

## Filters and Statistics

- ▶ Entries have diverse type of metainformation:
  - ▶ grammatical information
  - ▶ geographic source
  - ▶ register type
  - ▶ domain knowledge
- ▶ Filtering allows reports for specific kinds:
  - ▶ a list of terms from a specific geographic location
  - ▶ terms from a specific knowledge area
  - ▶ etc.
- ▶ Statistics:
  - ▶ allow to evaluate relevance of classes  
*How many entries in the cutlery domain?*
  - ▶ Allow to validate possible duplicated tags

# Lexicographic Support Tools

## Filters and Statistics



# Lexicographic Support Tools

## Reports

- ▶ Allow to create custom reports on work evolution:
  - ▶ list of entries accordingly with their state (imported, new, edited, and revised)
  - ▶ digital only entries
  - ▶ entries from a specific defined list (given a text file with the list of terms)

# Lexicographic Support Tools

## Validation and Backup

- ▶ Validation:
  - ▶ LeXmart validates for well-formedness of the XML
  - ▶ LeXmart does not validate for DTD/Schema compliance in run time
  - ▶ Reports can be requested on Schema compliance

# Lexicographic Support Tools

## Validation and Backup

- ▶ Validation:
  - ▶ LeXmart validates for well-formedness of the XML
  - ▶ LeXmart does not validate for DTD/Schema compliance in run time
  - ▶ Reports can be requested on Schema compliance
- ▶ Backups:
  - ▶ eXist-DB backups are dumps of XML files
  - ▶ These files can be stored in a control version software
  - ▶ Using GIT allows us to have backups and version control easily

# Content Management System

- ▶ Dictionaries are not just a list of definitions:
  - ▶ introduction
  - ▶ explanation of micro and macro structure
  - ▶ other decisions...
- ▶ Information to be shared by lexicographers:
  - ▶ rules when editing entries
  - ▶ general guidelines

- ▶ A simple CMS system was developed:
  - ▶ stored as independent collection on eXistDB
  - ▶ edited on a WYSIWYG editor (TinyMCE)
  - ▶ stored as XHTML
  - ▶ easy to display directly on a browser

- ▶ eXist-DB provides a RESTful API to:
  - ▶ fetch/store entries directly
  - ▶ query collections using XQuery
- ▶ On top of this, a generic user-centric API will be developed:
  - ▶ simple access to search/reverse search
  - ▶ filtering accordingly with entries metadata



# Conclusions

- ▶ Solution based on Web-technologies
- ▶ Based on XML-aware database
- ▶ Extensible
- ▶ Available freely on GitLab (see <http://lexmart.eu>)
- ▶ Being used on a real dictionary project

# Future Work

- ▶ Translate the software
- ▶ Add configuration properties
- ▶ Stick to TEI and/or TEI Lex-0 standards
- ▶ Create “print-friendly” formats (XSL-FO or  $\text{\LaTeX}$ )
- ▶ Integrate with other technologies:
  - ▶ ontologies and triple stores
  - ▶ wordnets

# LeXmart

## A Smart Tool for Lexicographers

A. Simões, A. Salgado, R. Costa & J. J. Almeida

