

# **EDICIÓN DIXITAL SEN ESTRÉS TECNOLÓXICO: DAS FONTES Á WEB**

**Helena Bermúdez Sabel**

# CONTIDOS

- Fluxos de trabajo automatizados
- Introducción a XML e TEI
- Introducción a TEI Publisher
- Ejercicio práctico

# INFORMACIÓN PRELIMINAR

- Guía da sesión: <https://helenasabel.github.io/obradoiro.html>

# FLUXOS DE TRABALHO AUTOMATIZADOS

# TRANSCRIPCIÓN AUTOMÁTICA

- De imaxes a textos electrónicos (anotados)
- Ferramentas OCR e HTR. Algúns exemplos:
  - Extensións dos navegadores:
    - Image Reader OCR, Copyfish
  - Móbil:
    - Google Keep
  - PC:
    - Tesseract, Zotero OCR, Transkribus
    - Editores de PDF con tecnoloxía OCR: Adobe Acrobat, Wondershare PDFelement Pro
  - Plataformas web:
    - Windows: Text Recognition, Soda PDF, Docsumo, Google Drive, Transkribus.ai

# TRANSCRIPCIÓN AUTOMÁTICA

- Disponibilidad de modelos pre-adestrados e algoritmos de adiestramiento fáciles de usar
- Conversión de archivos en formatos de transcripción a archivos semanticamente anotados (XML-TEI) a través de:
  - scripting (ex. DiScholEd, LECTAUREP - Page2tei, Transkribus)
  - aprendizaje automático (*machine learning*): Khemakhem et al. (2017), Pagel et al. (2021).

# COLACIÓN AUTOMÁTICA

- Colación: comparación das lecturas de dous ou máis testemuños
- As ferramentas de colación automática reciben como entrada a transcripción de cada testemuño; estas transcripcións alíñanse entre si mediante un algoritmo de alíñación.

# COLACIÓN AUTOMÁTICA

- Ferramentas:
  - LERA - Locate, Explore, Retrace and Apprehend complex text variants
  - Variance viewer
  - CollateX
  - Hypercollate
- Para saber más:
  - Obradoiro de introdución á colación automática (en inglés).

# ANOTACIÓN AUTOMÁTICA

- Ferramentas de procesamento da linguaxe. Tarefas máis habituais:
  - Lematización, etiquetaxe gramatical e descrición morfosintáctica
  - Recoñecemento e desambiguación de entidades nomeadas
  - Análise de sentimentos e emocións
  - Modelado de tópicos, extracción de palabras-chave
  - Anotación de elementos de versificación (rima, encabalgamento, escansión)
  - Anotación de figuras retóricas

# ANOTACIÓN TEXTUAL

- CATMA
- Semanticat
- TUSTEP
- Anotación crítica
  - Classical Text Editor
  - TEI Critical Apparatus Toolbox

## ENTORNOS VIRTUAIS DE INVESTIGACIÓN

- Sistemas en liña que facilitan a colaboración entre investigadoras/es. No contexto da edición, xeralmente inclúen ferramentas relacionadas co almacenamento de documentos e imaxes, anotación de imaxes e documentos, análise textual, visualización, etc.

Entornos de investigación virtuales, herramientas para la publicación e explotación de corpus


- CETELcean
- Ed. A Jekyll Theme for Minimal Editions
- Ediarium
- eLaborate
- FairCopy
- LEAF-Writer
- TEI Publisher
- TEITOK
- TEIViewer
- TextGrid
- Textual Communities
- TXM

# INTRODUCCIÓN A XML E TEI

## MARCAR IMPLICA...

... modelar a estrutura inherente dun texto e as súas propiedades semánticas a partir de:

- Xerarquías
- Estruturas ordenadas
- Linguaxe humana + linguaxe computacional



# TIPOS DE MARCADO


- Descriptivo
- Presentación
- Procedural
- **Multifacético**

# QUE É XML?

- Formato para o almacenamento e transmisión de datos
- Definido polo World Wide Web Consortium (W3C)
- Uso moi extenso

```
<poem>
  <stanza>
    <l>Valenz Senher, rei dels Aragones</l>
    <l>a qi prez es honors tut iorn enansa,</l>
    <l>remembre vus, Senher, del Rei franzes</l>
    <l>qe vus venc a vezer e laiset Fransa</l>
  </stanza>
  <stanza>
    <l>Ab dos sos fillz es ab aquel d'Artes;</l>
    <l>hanc no fes colp d'espaza ni de lansa</l>
    <l>e mainz baros menet de lur paes:</l>
    <l>jorn de lur vida said n'auran menbransa.</l>
  </stanza>
  <stanza>
    <l>Vostre Senhier faccia a vus compagna</l>
    <l>per qe en ren no vus qal[la] duptar;</l>
    <l>tals quida hom qe perda qe gazaingna.</l>
  </stanza>
  <stanza>
    <l>Seigner es de la terra e de la mar,</l>
    <l>per qe lo Rei Engles e sel d'Espangna</l>
    <l>ne varran mais, si.ls vorres ajudar.</l>
  </stanza>
</poem>
```





# SINTAXE XML

- Elemento: <l> </l>
- Atributo: <l met="3" rhyme="a">
- Nós textuais:


```
<l met="3" rhyme="a">Frutales</l>  
<l met="3" rhyme="b">cargados.</l>  
<l met="3" rhyme="b">Dorados</l>  
<l met="3" rhyme="a">trigales...</l>
```

```
<poem>
  <stanza type="quatrain">
    <l>Valenz Senher, rei dels Aragones</l>
    <l>a qi prez es honors tut iorn enansa,</l>
    <l>remembre vus, Senher, del Rei franzes</l>
    <l>qe vus venc a vezer e laiset Fransa</l>
  </stanza>
  <stanza type="quatrain">
    <l>Ab dos sos fillz es ab aquel d'Artes;</l>
    <l>hanc no fes colp d'espaza ni de lansa</l>
    <l>e mainz baros menet de lur paes:</l>
    <l>jorn de lur vida said n'auran menbransa.</l>
  </stanza>
  <stanza type="tercet">
    <l>Vostre Senhier faccia a vus compagna</l>
    <l>per qe en ren no vus qal[la] duptar;</l>
    <l>tals quida hom qe perda qe gazaingna.</l>
  </stanza>
  <stanza type="tercet">
    <l>Seigner es de la terra e de la mar,</l>
    <l>per qe lo Rei Engles e sel d'Espangna</l>
    <l>ne varran mais, si.ls vorres ajudar.</l>
  </stanza>
</poem>
```



```
<poem>
  <stanza type="quatrain">
    <l>Valenz Senher, rei dels Aragones</l>
    <l>a qi prez es honors tut iorn enansa,</l>
    <l>remembre vus, Senher, del Rei franzes</l>
    <l>qe vus venc a vezer e laiset Fransa</l>
  </stanza>
  <stanza type="quatrain">
    <l>Ab dos sos fillz es ab aqel d'Artes;</l>
    <l>hanc no fes colp d'espaza ni de lansa</l>
    <l>e mainz baros menet de lur paes:</l>
    <l>jorn de lur vida said n'auran menbransa.</l>
  </stanza>
  <stanza type="tercet">
    <l>Vostre Senhier faccia a vus compagna</l>
    <l>per qe en ren no vus qal<supplied>la</supplied>
      duptar;</l>
    <l>tals quida hom qe perda qe gazaingna.</l>
  </stanza>
  <stanza type="tercet">
    <l>Seigner es de la terra e de la mar,</l>
    <l>per qe lo Rei Engles e sel d'Espangna</l>
    <l>ne varran mais, si.ls vorres ajudar.</l>
  </stanza>
</poem>
```





## SINTAXE XML

- A árbore XML ten unha única raíz, é dicir, un único elemento que contén todos os demais elementos
- Todos os contidos están delimitados
- Non pode conter os caracteres &, < (substituír polas entidades correspondentes &amp; e &lt;)
- Todos os elementos deben estar aniñados correctamente: sen solapamentos!

## POR QUE XML?


- Sintaxe fácil e simple
- Lexível
- Control da entrada e saída
- Software e hardware independentes
- Soportado por unha ampla gama de software (aberto + propietario)

# XML E O MODELADO

- Modelado dun texto como xerarquías ordenadas de obxectos de contido (Renear et al. 1993)
  - Limitación: coexistencia de múltiples xerarquías lóxicas (o problema dos elementos superpostos)
  - Vantaxes do modelado:
    - As prácticas analíticas determinan frecuentemente xerarquías de obxectos (ou a descomposición en xerarquías adoita ser posible)
    - Lexíbel para persoas e máquinas
    - Sintaxe fácil

# A FAMILIA DE ESTÁNDARES XML

- Linguaxes de esquema
- XPath
- XSLT
- XQuery
- SVG
- HTML
- KML
- XSL-FO, XForms, XProc, OOXML, OpenOffice.orgXML



**Flanders (2018).**

# VÁLIDO VS. BEN FORMADO


- Ben formado: cumpre coas regras de XML
- Válido:
  - Uso correcto do vocabulario: os elementos e atributos usados están dispoñíbeis nesa lingua
  - Uso correcto da gramática: os elementos utilízanse no lugar axeitado seguindo a orde definida

# TEI COMO ESTÁNDAR XML

- Algunhas das vantaxes chave:
  - Interoperabilidade
  - Intercambio
  - Transferencia tecnolóxica
  - Eficiencia

## QUE É A TEXT ENCODING INITIATIVE (TEI)

- Conxunto de pautas para codificar documentos culturais
- Consorcio Internacional que mantén e desenvolve as devanditas directrices
- Comunidade de proxectos e investigadores/as que implementan as directrices da TEI



**Flanders (2018).**

## MODELADO EN TEI

- Definición do vocabulario
- Formalización das restricións
- Deseño do output (saída)

## AS DIRECTRICES TEI

- Divididas en dúas partes
  - Capítulos (comunmente denominadas “prosa”)
  - Especificacións (*specs*)

# VÁLIDO VS. BEN FORMADO

- Ben formado: cumpre coas regras de XML
- Válido:
  - Uso correcto do vocabulario: os elementos e atributos usados están dispoñíbeis nesa lingua
  - Uso correcto da gramática: os elementos utilízanse no lugar axeitado seguindo a orde definida
  - A validez garántese grazas á formalización dun esquema nalgunha das linguaxes de esquema

# LINGUAXES DE ESQUEMA

- W3C XML Schema (XML Schema or XSD)
- Document Type Definition (DTD)
- REgular LAnguage for XML Next Generation (**RELAX NG**)
  - sintaxe XML
  - sintaxe compacta
- **Schematron**
  
- **TEI ODD**: un formato de especificación conforme á TEI-XML que permite customizar o vocabulario TEI dunha maneira que responde á **programación letrada**.

# TEI ODD: ONE DOCUMENT DOES IT ALL

- Seleccionar módulos
- Eliminar elementos innecesarios
- Engadir novos elementos e/ou atributos
- Cambiar o nome dun elemento ou atributo
- Limitar os valores dun atributo
- Limitar a estrutura
- Manipular agrupacións funcionais de elementos
- Internacionalización (i-18n)
- Documentación
- Definir a saída a partir do **modelo de procesamento de TEI**

**POR QUE TEI PUBLISHER?**

## TEI PUBLISHER

- Software libre de código aberto
- Basado en estándares abiertos, con opciones por defecto que facilitan a anotación e publicación sen necesidade de programar
- Comunidade: **e-editions** (organización de base co obxectivo de sustentar edicións a partir da promoción de estándares abiertos e colaboración comunitaria)

**DEMO**

# EXERCICIO PRÁCTICO

EDICIÓN DE *CONTOS DA MIÑA TERRA*