

About digital collation

David J. Birnbaum (University of Pittsburgh)
Helena Bermúdez Sabel (Universidade de Santiago de Compostela)

Text as process: Genetic and textual criticism in the digital age
University of Pittsburgh, 2016-04-05

Outline

- What is collation?
- The Gothenburg model
- Collation tools
 - CollateX
 - Juxta
 - Versioning machine

What is collation?

- *What*: Alignment and comparison of textual witnesses
- *Why*: Support text-critical analysis and edition
- *Input*: Multiple textual witnesses to the same work
- *Output*: Alignment of variants

Types of variation

- Textual: insertion, deletion, mutation, transposition
- Substantive ~ non-substantive
 - Substantive: equipollent, linguistic, scribal error
 - Non-substantive: graphic
- Ignore non-substantive variation for comparison
 - Punctuation
 - Upper ~ lower case
 - Orthographic variation
 - Variant letterforms
 - Abbreviation

Types of output

1. Interlinear (synoptic) edition
- Variant table
2. Critical apparatus
3. Variant graph
4. Stemma codicum
5. TEI XML
6. Etc.

1. Interlinear (synoptic) edition

1.	A Mmœus amigos molto me praz <i>Nd amst//</i>
B	Mœ̄s amigos myro mj praz d'amor
V	Mœ̄s amigos myro mi praz d'amor
2.	A que entend ora que me quer matar
B	q entend [] que me aer matar
V	que entend ora que me quer matar
3.	A pois mi a min deus non quis nec mia senhor
B	pays mb a mj de non quis ne mba senhor
V	pays mb a mi de non quis ne mba sen
4.	A a que (o) roguei de me del amparar
B	a que roguey sempre del emparar
V	a que o roguey de me del emparar

- Blocks: lines
- Rows: witnesses
- Columns: aligned tokens
- In this edition
 - Bold: graphic variation
 - Underline: equipollent reading
 - Orange: scribal error
 - Blue: linguistic variant
 - Other: deletions (red), insertions (green)

2. Critical apparatus

I O meu Senhor [Dios] me güiou
de sosp' ja a cosa soler,
en quanto no mundo viver,
que me fizer dizer que non
non il ouvir dizer a [senhor].
20

5 E se Deus ovo grá prazer
de me fazer cosa levar,
que non me fizer dizer que
me fizer dizer cosa levar,
que me fizer dizer que non
25

10 Se m'ao a Deus mal mereci,
non vos quis El mimo tardar
que me fizer dizer cosa levar
de mi, u e tal dona vi
que me fizer dizer por senhor
15

15 que me fizer dizer a [senhor].
30

15 que me fizer dizer a [senhor].
35

Cantiga de amar de refan
Mss.: A 225, f. 60v; col. b; B 396, ff. 88v, col. b - 89r; col. a; V
6, f. 27v; v. 6, f. 1v, col. b)

1. Deus] ov. 4. [B] me] mi] B 4. [m] locu B 7. [ovo] ou-
ve B 7. 8. [m] mi] B 7. corri P 10. [m] mi] B 7. 11. [m]

- Main text (reconstructed)
- Text type
- Traditio textus (witnesses and loci)
- Apparatus criticus (negative)
 - Location, lemma, reading, sigla

2. Critical apparatus

I. Manuscritos, señales de errores,
y otros tipos de variantes.
1. Indicaciones de errores.
2. Señales de errores.
3. Señales de errores de los
manuscritos.

II. Textos en verso o en prosa,
y sus variantes.
1. Textos en verso.
2. Textos en prosa.
3. Textos en prosa de los
manuscritos.

III. Textos en verso o en prosa,
y sus variantes.
1. Textos en verso.
2. Textos en prosa.
3. Textos en prosa de los
manuscritos.

IV. Textos en verso o en prosa,
y sus variantes.
1. Textos en verso.
2. Textos en prosa.
3. Textos en prosa de los
manuscritos.

V. Textos en verso o en prosa,
y sus variantes.
1. Textos en verso.
2. Textos en prosa.
3. Textos en prosa de los
manuscritos.

VI. Textos en verso o en prosa,
y sus variantes.
1. Textos en verso.
2. Textos en prosa.
3. Textos en prosa de los
manuscritos.

VII. Textos en verso o en prosa,
y sus variantes.
1. Textos en verso.
2. Textos en prosa.
3. Textos en prosa de los
manuscritos.

VIII. Textos en verso o en prosa,
y sus variantes.
1. Textos en verso.
2. Textos en prosa.
3. Textos en prosa de los
manuscritos.

IX. Textos en verso o en prosa,
y sus variantes.
1. Textos en verso.
2. Textos en prosa.
3. Textos en prosa de los
manuscritos.

X. Textos en verso o en prosa,
y sus variantes.
1. Textos en verso.
2. Textos en prosa.
3. Textos en prosa de los
manuscritos.

XI. Textos en verso o en prosa,
y sus variantes.
1. Textos en verso.
2. Textos en prosa.
3. Textos en prosa de los
manuscritos.

XII. Textos en verso o en prosa,
y sus variantes.
1. Textos en verso.
2. Textos en prosa.
3. Textos en prosa de los
manuscritos.

XIII. Textos en verso o en prosa,
y sus variantes.
1. Textos en verso.
2. Textos en prosa.
3. Textos en prosa de los
manuscritos.

XIV. Textos en verso o en prosa,
y sus variantes.
1. Textos en verso.
2. Textos en prosa.
3. Textos en prosa de los
manuscritos.

XV. Textos en verso o en prosa,
y sus variantes.
1. Textos en verso.
2. Textos en prosa.
3. Textos en prosa de los
manuscritos.

XVI. Textos en verso o en prosa,
y sus variantes.
1. Textos en verso.
2. Textos en prosa.
3. Textos en prosa de los
manuscritos.

XVII. Textos en verso o en prosa,
y sus variantes.
1. Textos en verso.
2. Textos en prosa.
3. Textos en prosa de los
manuscritos.

XVIII. Textos en verso o en prosa,
y sus variantes.
1. Textos en verso.
2. Textos en prosa.
3. Textos en prosa de los
manuscritos.

XIX. Textos en verso o en prosa,
y sus variantes.
1. Textos en verso.
2. Textos en prosa.
3. Textos en prosa de los
manuscritos.

XX. Textos en verso o en prosa,
y sus variantes.
1. Textos en verso.
2. Textos en prosa.
3. Textos en prosa de los
manuscritos.

XI. Textos en verso o en prosa,
y sus variantes.
1. Textos en verso.
2. Textos en prosa.
3. Textos en prosa de los
manuscritos.

XII. Textos en verso o en prosa,
y sus variantes.
1. Textos en verso.
2. Textos en prosa.
3. Textos en prosa de los
manuscritos.

XIII. Textos en verso o en prosa,
y sus variantes.
1. Textos en verso.
2. Textos en prosa.
3. Textos en prosa de los
manuscritos.

XIV. Textos en verso o en prosa,
y sus variantes.
1. Textos en verso.
2. Textos en prosa.
3. Textos en prosa de los
manuscritos.

XV. Textos en verso o en prosa,
y sus variantes.
1. Textos en verso.
2. Textos en prosa.
3. Textos en prosa de los
manuscritos.

XVI. Textos en verso o en prosa,
y sus variantes.
1. Textos en verso.
2. Textos en prosa.
3. Textos en prosa de los
manuscritos.

XVII. Textos en verso o en prosa,
y sus variantes.
1. Textos en verso.
2. Textos en prosa.
3. Textos en prosa de los
manuscritos.

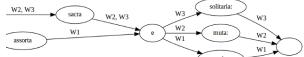
XVIII. Textos en verso o en prosa,
y sus variantes.
1. Textos en verso.
2. Textos en prosa.
3. Textos en prosa de los
manuscritos.

XIX. Textos en verso o en prosa,
y sus variantes.
1. Textos en verso.
2. Textos en prosa.
3. Textos en prosa de los
manuscritos.

XX. Textos en verso o en prosa,
y sus variantes.
1. Textos en verso.
2. Textos en prosa.
3. Textos en prosa de los
manuscritos.

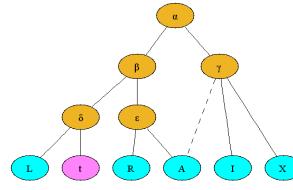
- Significant variants
 - Equipollent (textual)
 - Linguistic
 - Scribal error
- Insignificant variants
 - Graphic
- History of edition
 - Critical annotations from prior editions (negative)

3. Variant graph



- Directed graph
- Nodes: readings
- Rank: alignment
- Edges: witness labels

4. Stemma codicum



- Hypothesis about textual transmission
- Nodes
 - Greek sigla, ochre: hypothetical
 - Upper-case Latin sigla, aqua: extant manuscripts
 - Lower-case Latin sigla, violet: lost manuscripts
- Edges
 - Solid line: antigraph → apograph
 - Dotted line: contamination

5. TEI parallel segmentation

```

<>
<app>
  <rdg wit="#one">se</rdg>
  <rdg wit="#two"><add>me</add></rdg>
  <rdg wit="#three">me</rdg>
</app>
atormentan
<app>
  <rdg wit="#one #two">en el jardín</rdg>
</app>
</>

```

- Plain text: Shared textual reading
- <app>: Variation locus
- <rdg>: Textual variant
- @wit: Sigla of witnesses

6. Other output formats

- Plain text variation table
- HTML variation table
- XML variation table
- GraphViz DOT
- Etc.

The Gothenburg model

- History and goals
- Components
 1. Tokenization
 2. Normalization/regularization
 3. Alignment
 4. Analysis
 5. Visualization/output

The Gothenburg model: history and goals

- Developers of CollateX and Juxta
- Gothenburg 2009 joint workshop
- Sponsored by COST Action 32 and Interedition
- Identify core components of textual comparison at an abstract level

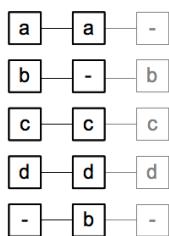
1. Tokenization

- (Presumes transcription and digitization)
- Divide the continuous text into units to be aligned (tokens)
- Typically whitespace-delimited words
 - May be at any level of granularity
 - “Syllables, words, lines, phrases, verses, paragraphs or text nodes”
- Challenges
 - Ambiguity
 - Punctuation
 - Contraction, superscription, etc.
 - Markup

2. Normalization/regularization

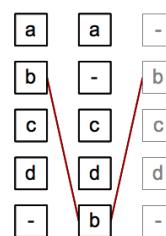
- Normalization during transcription ~ collation
- Ignore non-substantive variation for comparison
 - Punctuation
 - Upper ~ lower case
 - Orthographic variation
 - Variant letterforms
 - Abbreviation
- What goes into the output?

3. Alignment



- Alignment table
- Depth vs breadth
- Complications
 - Repetition
 - Transposition
 - Order effects
 - Computational complexity
 - Exact vs near (fuzzy) matching

4. Analysis/feedback



- Interpretation beyond linear alignment
- Manual intervention?

5. Visualization/output

- Markup, for further processing
 - XML, TEI, JSON, GraphViz DOT, LaTeX, etc.
- Textual alignment table, final form for edition
 - Plain text, HTML, PDF
- Textual visualization, for examination and analysis
 - Juxta
 - Versioning machine
- Graphic visualization, for examination and analysis
 - Variant graph

CollateX

- Java, Web app, and Python module
 - CollateX Java version:
 - <http://collatex.net>
 - CollateX Python package:
 - <https://pypi.python.org/pypi/collatex>
 - CollateX Python tutorial:
 - <http://collatex.obdurodon.org>
- Input: Anything at all (JSON)
- Output: Anything at all (JSON)

<i>Line 1</i>	Draft	\\\\$1// te atreves a (---der) sorprender
	Published	Si te atreves a sorprender
<i>Line 2</i>	Draft	el sentido de esta vieja pared;
	Published	la verdad de esta vieja pared;
<i>Line 3</i>	Draft	y sus fisuras\\$(\\$) desgarraduras(=),
	Published	y sus fisuras, desgarraduras,
<i>Line 4</i>	Draft	formando rostros, esfinges,
	Published	formando rostros, esfinges,
<i>Line 5</i>	Draft	manos, clepsidras, (=)
	Published	manos, clepsidras,

Juxta

- Stand-alone desktop application
 - Input: XML and plain text
 - Output: Analytic visualizations
 - Side-by-side collation view
 - Heat map
 - Histogram
 - Critical apparatus
 - Annotation and image support
- Juxta Commons (online tool)

Juxta collation features

- Selection of base text
- Normalization
 - Punctuation
 - Case
 - Whitespace
- Accept/reject revisions

Juxta disadvantages

- Limited options for normalization
- The base text must be a single, specific witness
 - Does not support a dynamic base text
- Loss of mark-up information other than addition and deletion
 - E.g., abbreviation, editorial regularization, etc.
- Limited control over the publication style

Versioning machine

- Visualizes alignment; does not perform collation
- Input: TEI aligned texts (parallel segmentation method)
 - Developer determines collation to prepare input
- Visualization features and facsimile image support

Using the Versioning machine for publication

- Displays multiple layers of textual information
 - Preserves markup
- Selection of default behaviors (well documented)
- Code reuse: customization (programming experience required)

Summary

- CollateX
 - Benefit: Complete control over input, tokenization, normalization, collation, and visualization
 - Limitation: Requires user programming (Python, possibly others)
- Juxta
 - Benefit: Analytical tools (histogram, heat map, annotation)
 - Limitation: No control over output, loss of markup information
- Versioning machine
 - Benefit: User control over output
 - Limitation: Requires TEI parallel segmentation input, output control requires user programming (XSLT, CSS)

Thank you!

- David J. Birnbaum (University of Pittsburgh)
 - djb@pitt@gmail.com
 - <http://www.obdurodon.org>
- Helena Bermúdez Sabel (Universidade de Santiago de Compostela)
 - helena.bermudez@usc.es
 - <http://gl-pt.obdurodon.org>

