

Enchaîner les IA

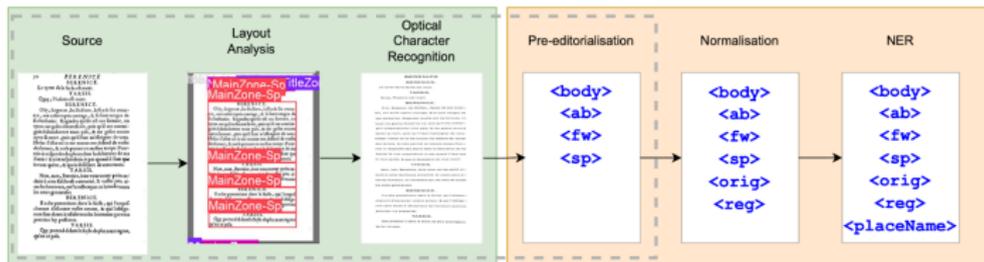
Vom Bild zum kodierten Dokument

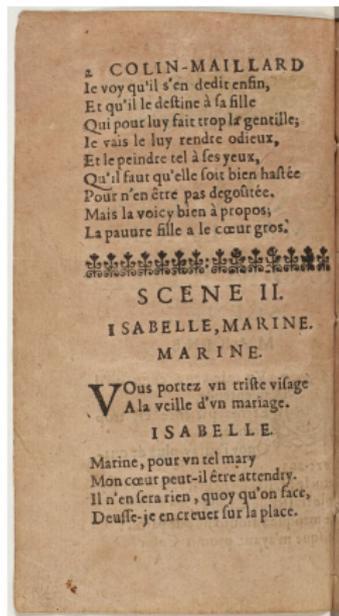
Simon Gabay ¹

¹Université de Genève
prenom.nom@unige.ch



- Texterkennung (optical character recognition, OCR) ist nicht die einzige wichtige Technologie für Bibliotheken.
- Viele Aufgaben (*tasks*) sind auch wichtig :
Layoutanalyse, Textnormalisierung,
Eigennamenerkennung, etc.
- Diese Aufgaben sind nicht trivial, sondern erfordern erhebliche philologische Arbeit.





2 COLIN-MAILLARD
le voy qu'il s'en dedit enfin,
Et qu'il le destine à sa fille
Qui pour luy fait trop la gentille ;
le vais le luy rendre odieux,
Et le peindre tel à ses yeux,
Qu'il faut qu'elle soit bien hastée
Pour n'en être pas degoutée.
Mais la voycy bien à propos ;
La pauvre fille a le cœur gros.

SCENE II
ISABELLE, MARINE
MARINE
VOus portez vn triste visage
A la veille d'vn mariage.
ISABELLE.
Marine, pour vn tel mary
Mon cœur peut-il être attendry.
Il n'en sera rien, quoy qu'on face,
Deusse-je encreuer sur la place.

Figure – Samuel Chappuzeau,
Le colin-maillard, Paris :
Jean-Baptiste Loyson, 1662

Source : Gallica

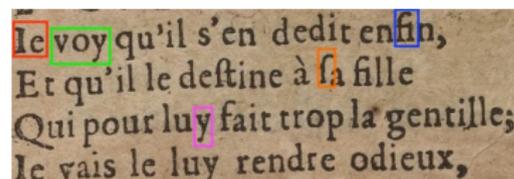


Figure – Samuel Chappuzeau,
Le colin-maillard, Paris :
Jean-Baptiste Loyson, 1662
Source : Gallica

- **Entwicklungen des Alphabets**
(Unterscheidung *i/j* und *u/v*, sogenannte „Ramistische Buchstaben“)
- **Alte Konjugationen**
(Erste Person ohne *s* vor der analogen Reparatur)
- **Alte Buchstaben**
(Formvariante für den Buchstaben *s*)
- **Antike Verwendungen**
(*y* kalligraphisch)

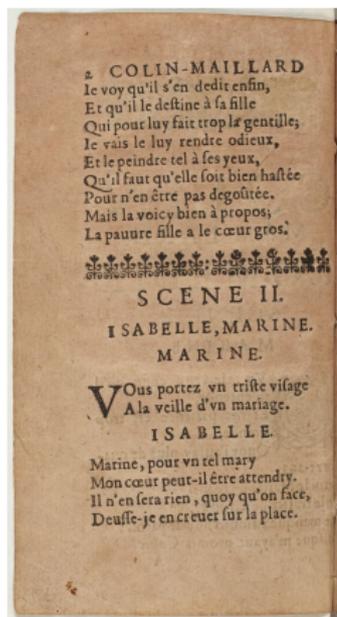


Figure – Samuel Chappuzeau,
Le colin-maillard, Paris :
Jean-Baptiste Loyson, 1662
Source : Gallica

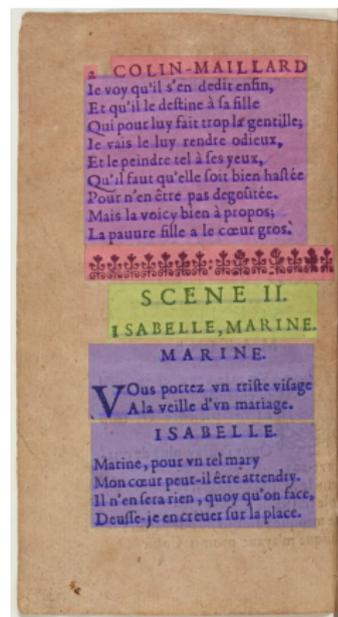


Figure – Automatische
Erkennung von Zonen mit
SegmOnto/LaDaS-gesteuertem
Vokabular.

```
<fw>2</fw>
<fw>COLIN-MAILLARD</fw>
<lb>Ie voy qu'il s'en dedit enfin,
<lb>Et qu'il le destine à sa fille
<lb>Qui pour luy fait trop la gentille;
<lb>Ie vais le luy rendre odieux,
<lb>Et le peindre tel à ses yeux,
<lb>Qu'il faut qu'elle soit bien hastée
<lb>Pour n'en être pas degoûtée.
<lb>Mais la voicy bien à propos;
<lb>La pauvre fille a le cœur gros.
</sp>
<head>SCENE II.
  <lb>ISABELLE, MARINE</head>
<sp>MARINE
  <lb>VOus porterez vn triste visage
  <lb>A la veille d'vn mariage
</sp>
<sp>ISABELLE
  <lb>Marine, pour vn tel mary
  <lb>Mon cœur peut-il être attendry.
  <lb>Il n'en sera rien, quoy qu'on face,
  <lb>Deusse-je en creuer sur la place.
</sp>
```



Figure – Beispiel für eine automatische TEI-Kodierung (Proto-Edition).

Figure – Automatische Erkennung von Zonen mit SegmOnto/LaDaS-gesteuertem Vokabular.

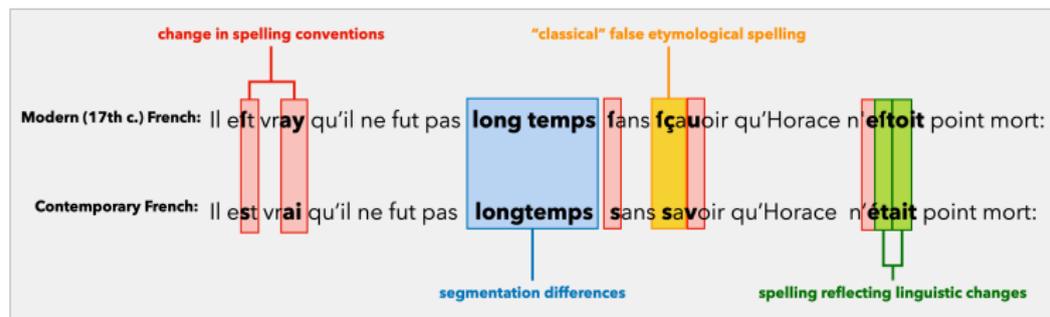


Figure – Beispiel für linguistische Normalisierung

- Für die automatische Transkription spricht man von einer
 - allographetische Transkription
 - graphematische Transkription
- Für der Transkription für eine Ausgabe spricht man von einer
 - (semi-)diplomatische Transkription
 - interpretierende Transkription

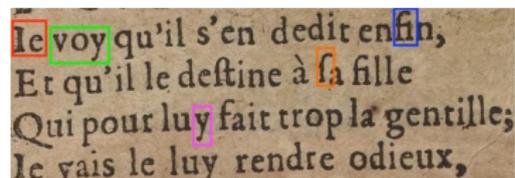


Figure – Samuel Chappuzeau,
Le colin-maillard, Paris :
Jean-Baptiste Loyson, 1662
Source : Gallica

le **voy** qu'il s'en dedit en**fin**,
Et qu'il le destine à **la** fille
Qui pour **luy** fait trop la gentille ;
Je vais le luy rendre odieux,

le **voy** qu'il s'en dedit en**fin**,
Et qu'il le destine à **sa** fille
Qui pour **luy** fait trop la gentille ;
Je vais le luy rendre odieux,

Je **voy** qu'il s'en dedit en**fin**,
Et qu'il le destine à **sa** fille
Qui pour **lui** fait trop la gentille ;
Je vais le lui rendre odieux,

Je **vois** qu'il s'en dédit en**fin**,
Et qu'il le destine à **sa** fille
Qui pour **lui** fait trop la gentille ;
Je vais le lui rendre odieux,

Es muss nicht nur das Ergebnis der Normalisierung erhalten bleiben, sondern *alle* Zustände des Textes.

```
<sp>
  <ab>
    <seg>
      <orig>SGANARELLE.</orig>
      <reg>SGANARELLE.</reg>
    </seg>
    <seg>
      <orig>Promettez-moy donc, Seigneur Geronimo, de me parler avec toute
      forte de franchise.</orig>
      <reg>Promettez-moi donc, Seigneur Geronimo, de me parler avec toute
      sorte de franchise.</reg>
    </seg>
  </ab>
</sp>
<sp>
  <ab>
    <seg>
      <orig>GERONIMO.</orig>
      <reg>GERONIMO.</reg>
    </seg>
    <seg>
      <orig>Je vous le promets.</orig>
      <reg>Je vous le promets.</reg>
    </seg>
  </ab>
</sp>
```

Figure – Beispiel einer XML-TEI-Kodierung mit Normalisierung.

Token	Lemma	POS	COARSE	FINE	FINE-COMP	NESTED	Wikidata ID
Les	le	Da	O	O	O	O	—
allemands	allemand	Nc	O	O	O	O	—
élurent	élire	Vvc	O	O	O	O	—
pour	pour	S	O	O	O	O	—
empereur	empereur	Nc	B-pers	B-pers.ind	B-comp.title	O	Q438435
Rodolphe	Rodolphe	Np	I-pers	I-pers.ind	B-comp.name	O	Q438435
duc	duc	Nc	I-pers	I-pers.ind	B-comp.title	O	Q438435
de	de	S	I-pers	I-pers.ind	I-comp.title	O	Q438435
Suabe	Souabe	Np	I-pers	I-pers.ind	I-comp.title	B-loc.adm.reg	Q438435

Table – Erkennung und Begriffsklärung benannter Entitäten

[Pedro Ortiz Suarez, Simon Gabay. A Data-driven Approach to Named Entity Recognition for Early Modern French. *Computational Linguistics*, Oct 2022, Gyeongju, South Korea. pp.3722-3730. hal-04110765]

Hier stellen wir nur einige Beispiele vor :

- 1 Automatische Erstellung von Metadaten
- 2 Textanreicherung
- 3 etc.