

# Corpus Assembly as Text Data Integration from Digital Libraries and the Web



Udo Hahn & Tinghui Duan

Jena University Language & Information Engineering (JULIE) Lab

<https://julielab.de/>

DFG Graduate School „Romanticism as a Model“

<http://modellromantik.uni-jena.de>

Friedrich Schiller University Jena, Germany

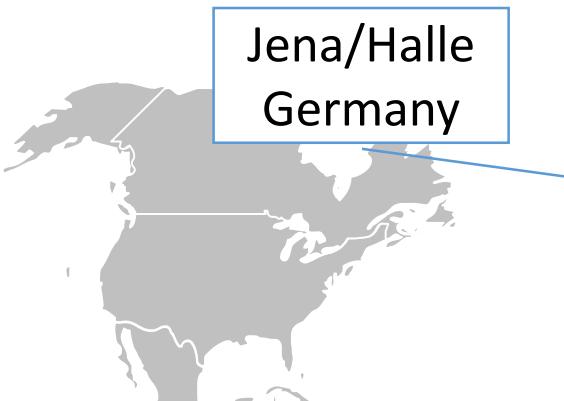
Jun 3 2019 – Urbana-Champaign IL

JCDL 19' – Session 1A – *Generation and Linking*

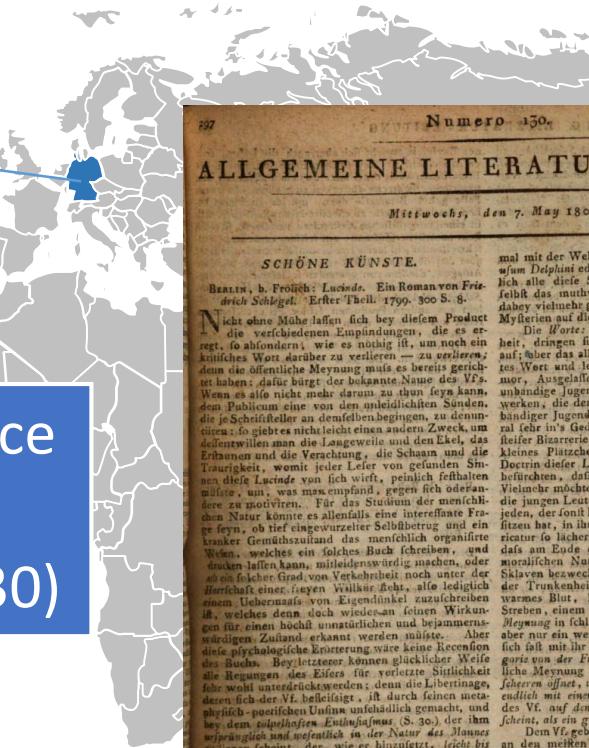


# Allgemeine Literatur-Zeitung (1785-1849)

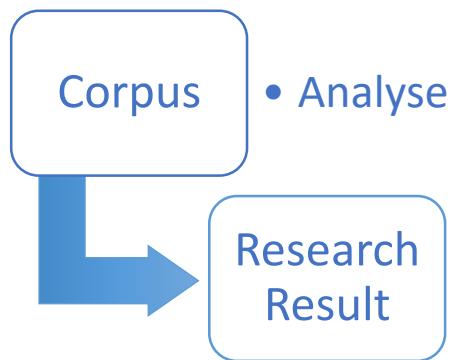
## General Literature Gazette, ALZ



Very important historical text source  
for literary studies  
in German Romanticism (1790-1830)

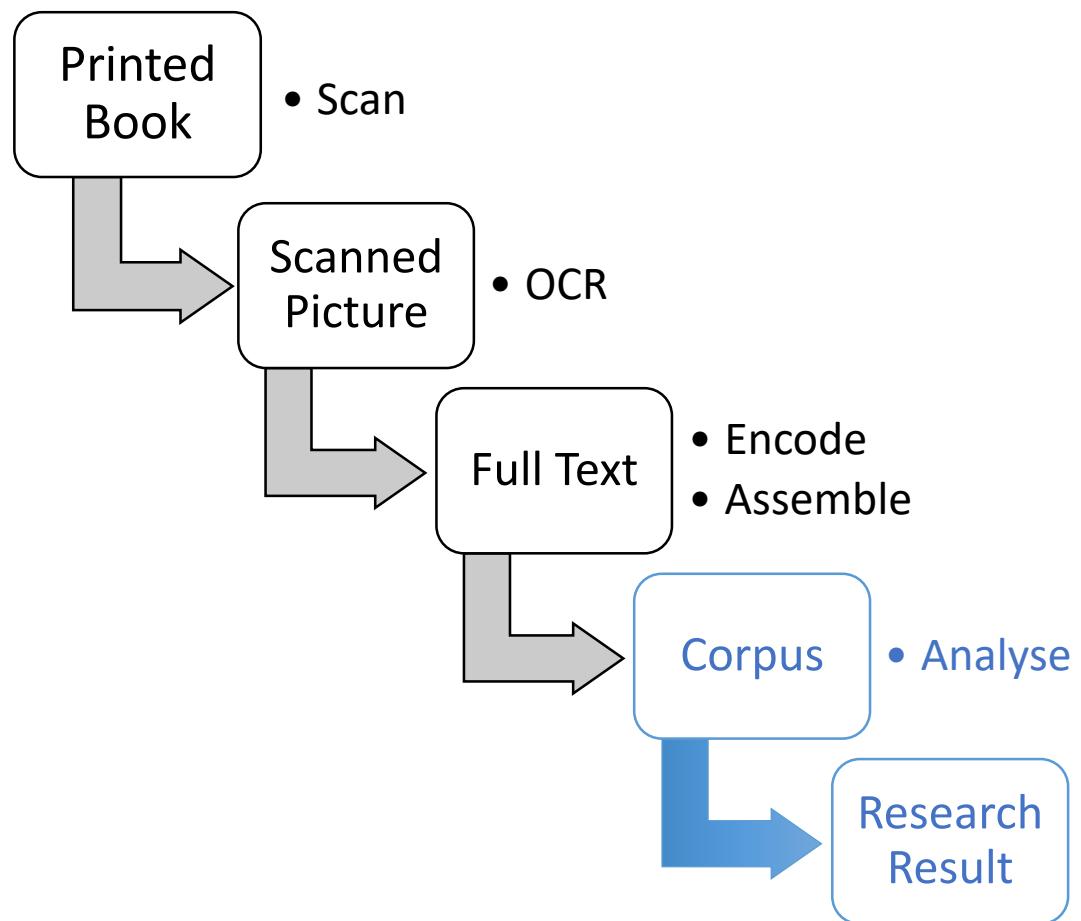


# Allgemeine Literatur-Zeitung (1785-1849)



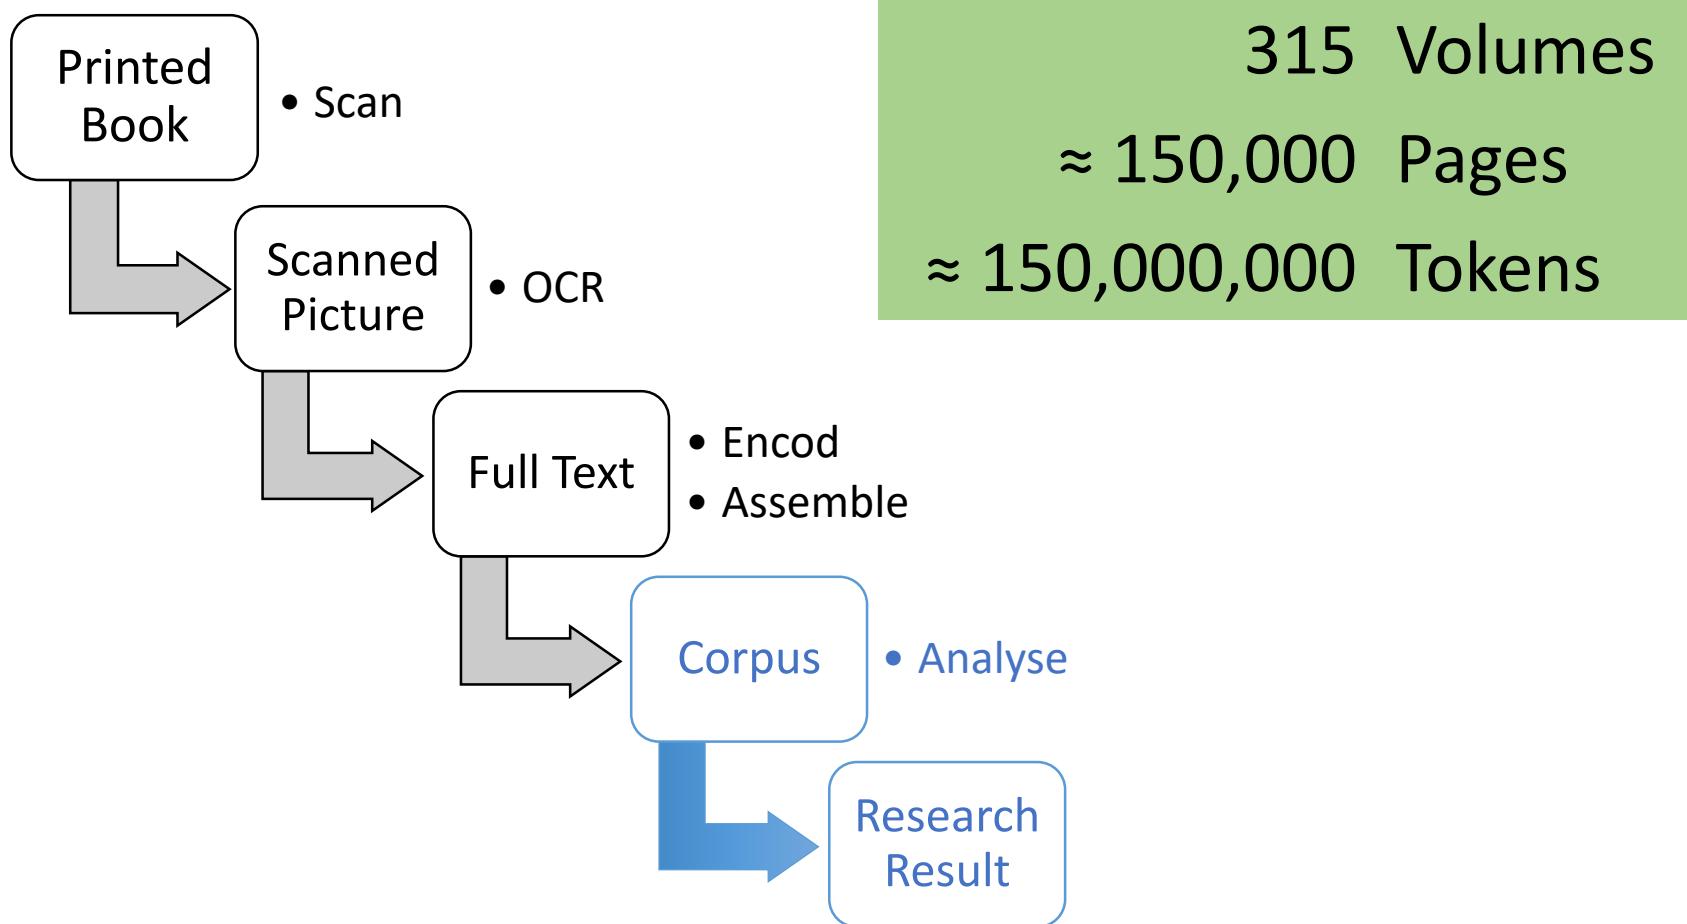
# Allgemeine Literatur-Zeitung (1785-1849)

## Traditional Workflow



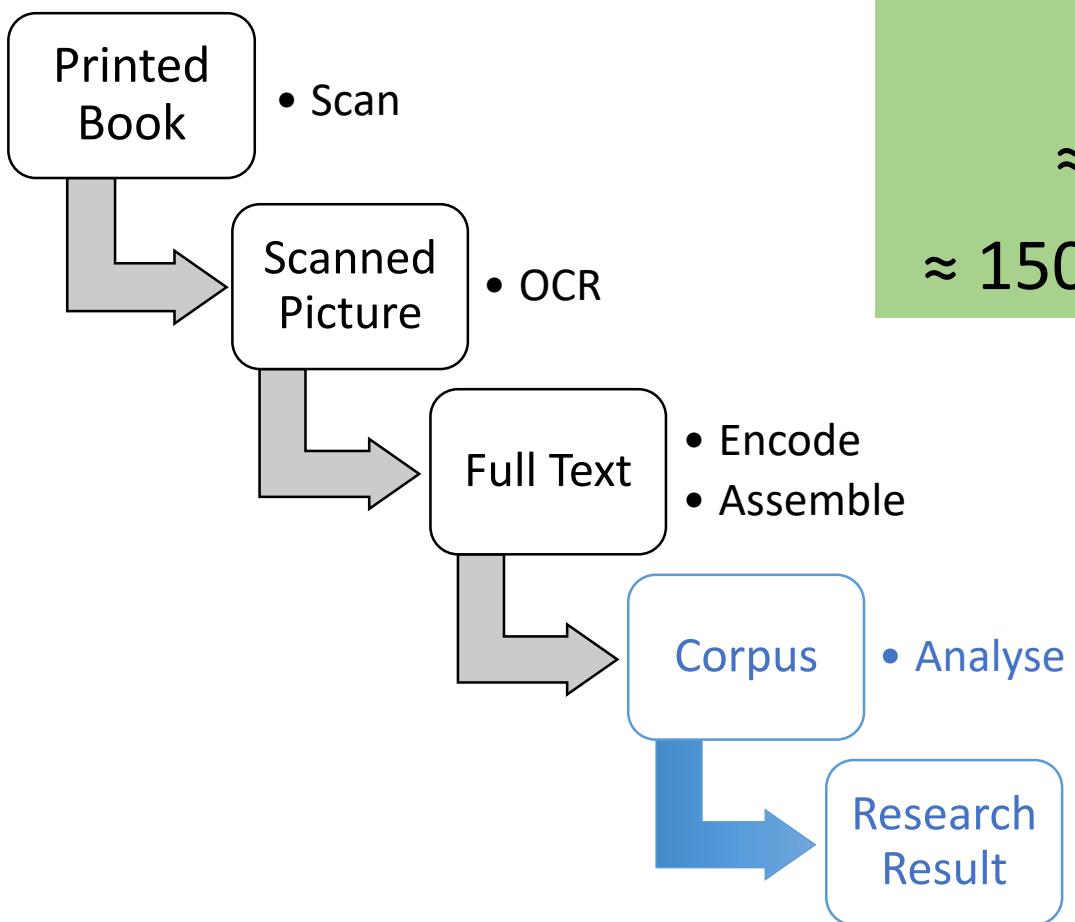
# Allgemeine Literatur-Zeitung (1785-1849)

## Traditional Workflow



# Allgemeine Literatur-Zeitung (1785-1849)

## Traditional Workflow

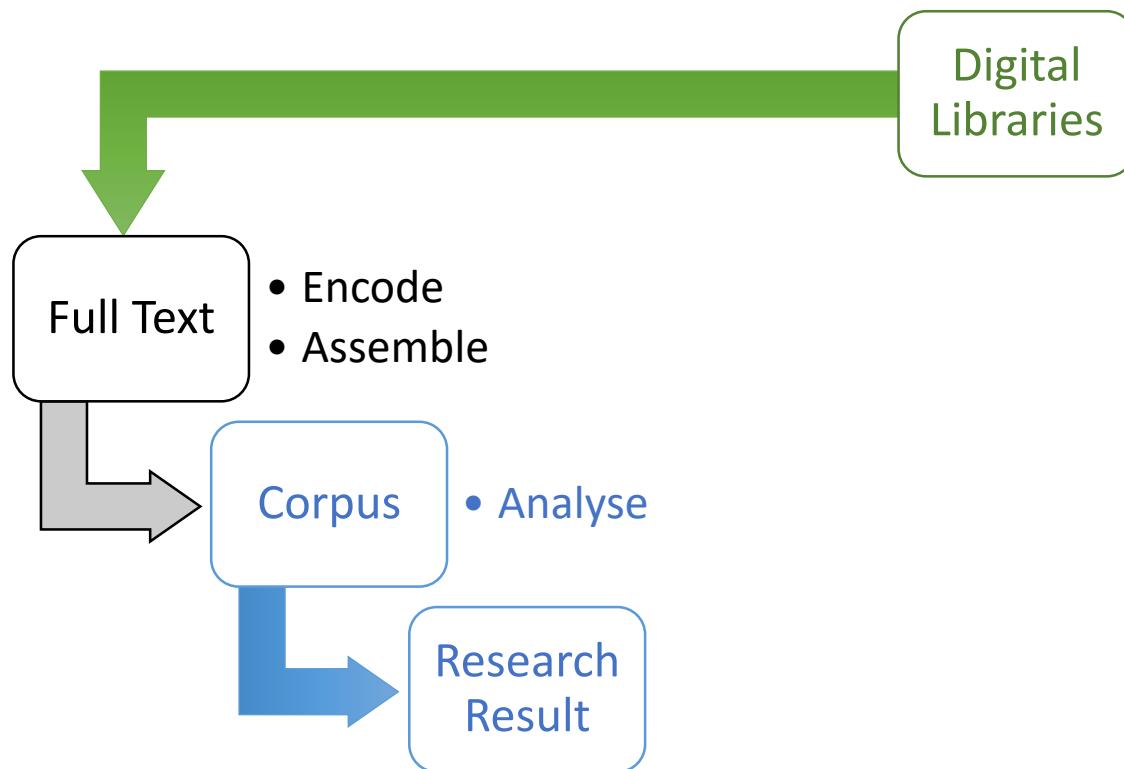


315 Volumes  
≈ 150,000 Pages  
≈ 150,000,000 Tokens

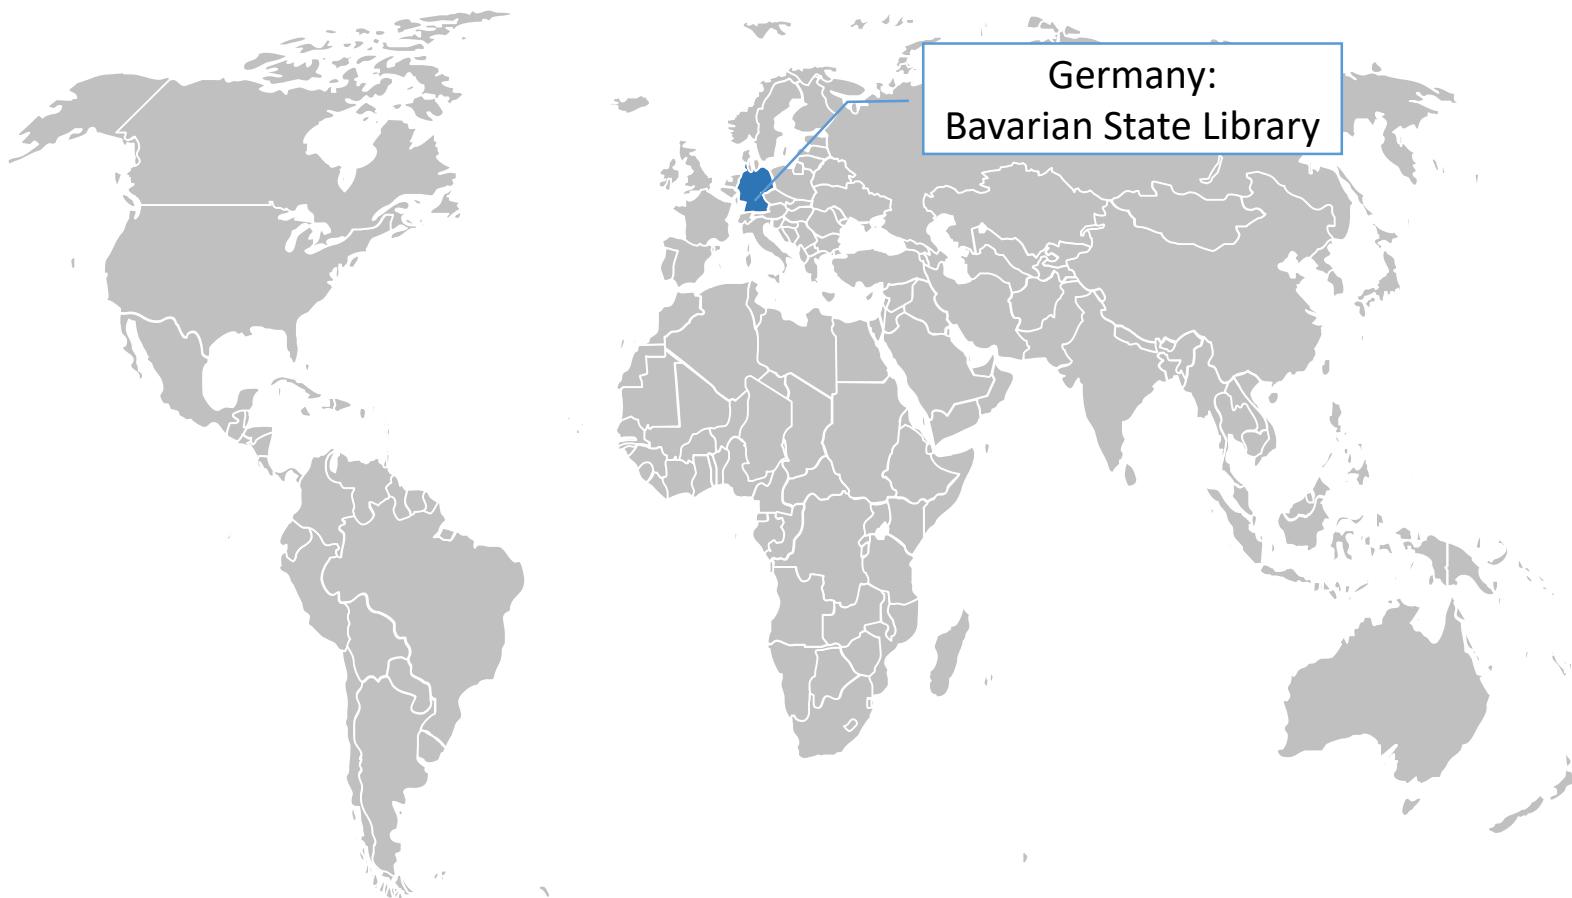
**Cost- and Time-  
Consuming**

# Allgemeine Literatur-Zeitung (1785-1849)

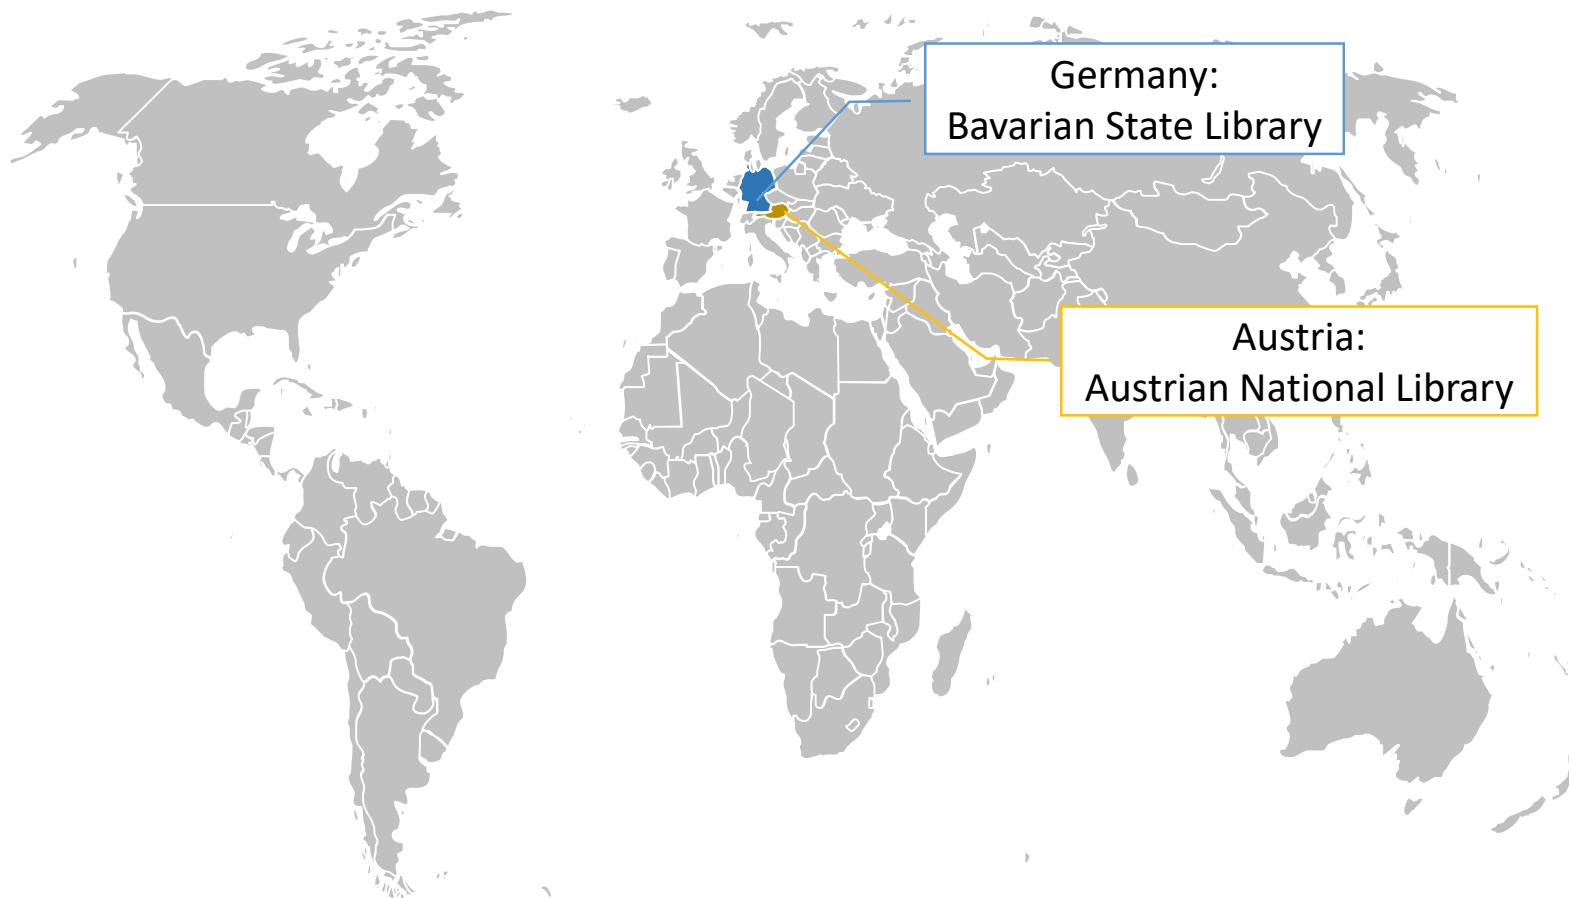
## Alternative Workflow



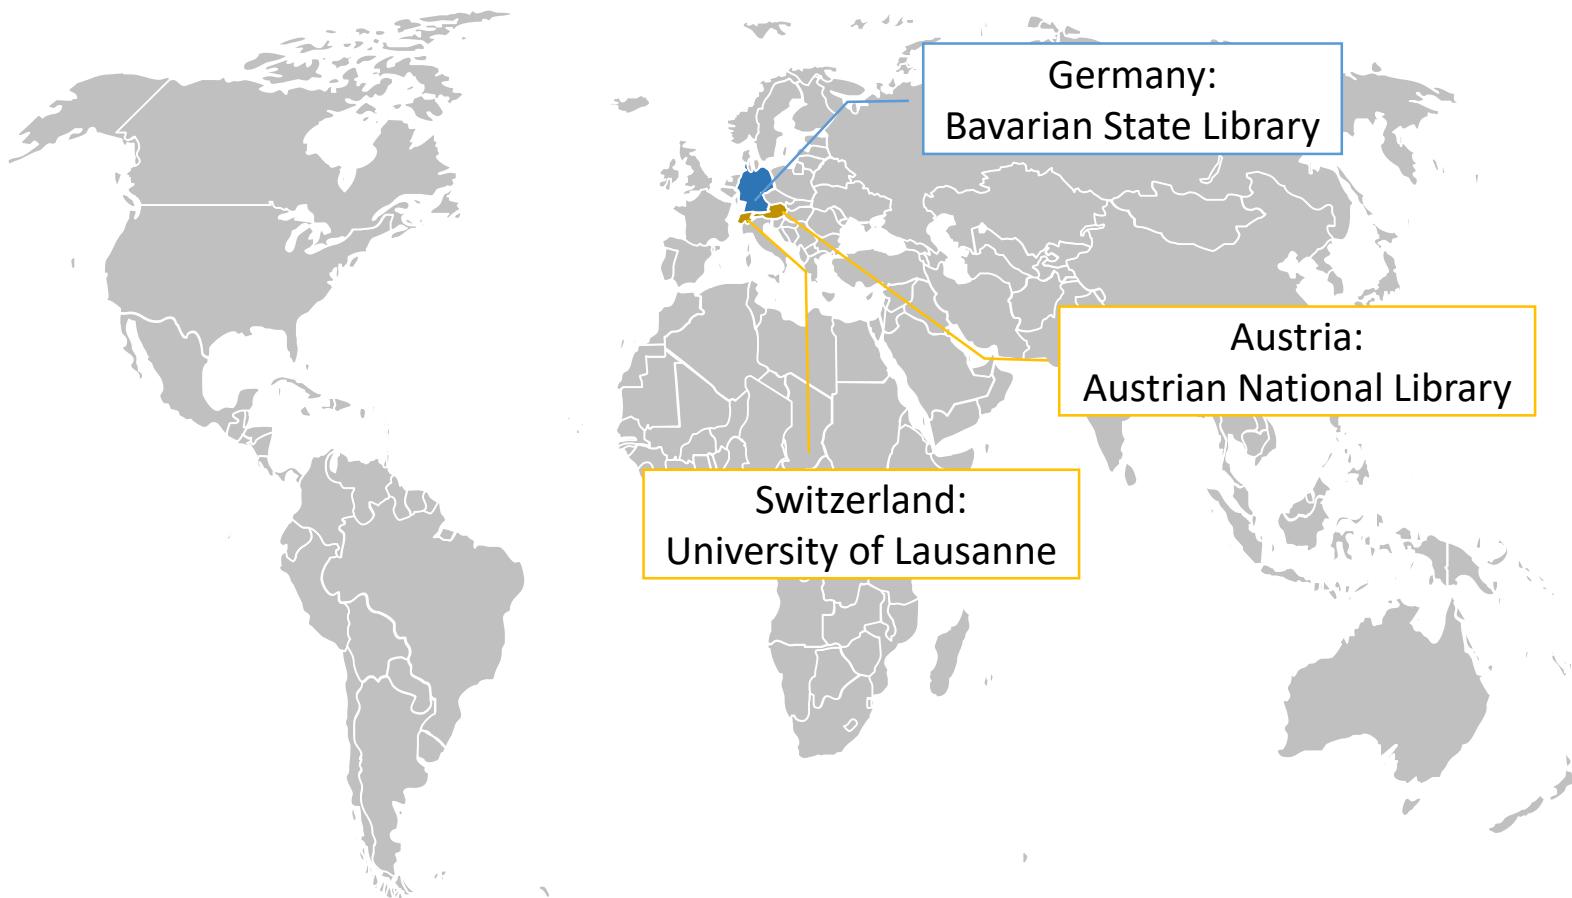
# Scattered Digital Resources of ALZ



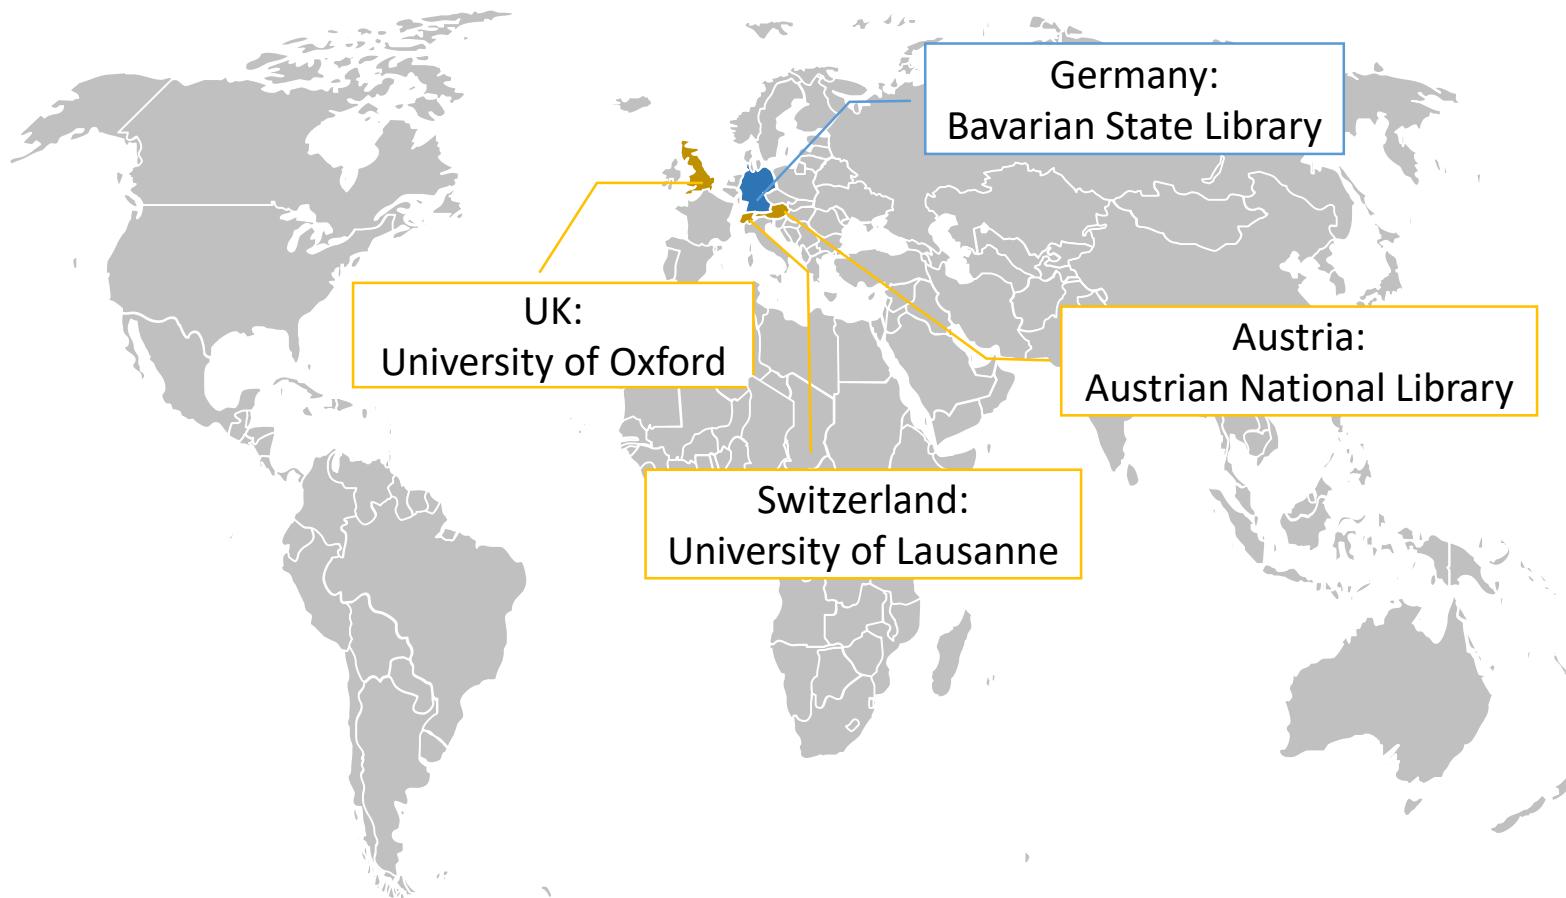
# Scattered Digital Resources of ALZ



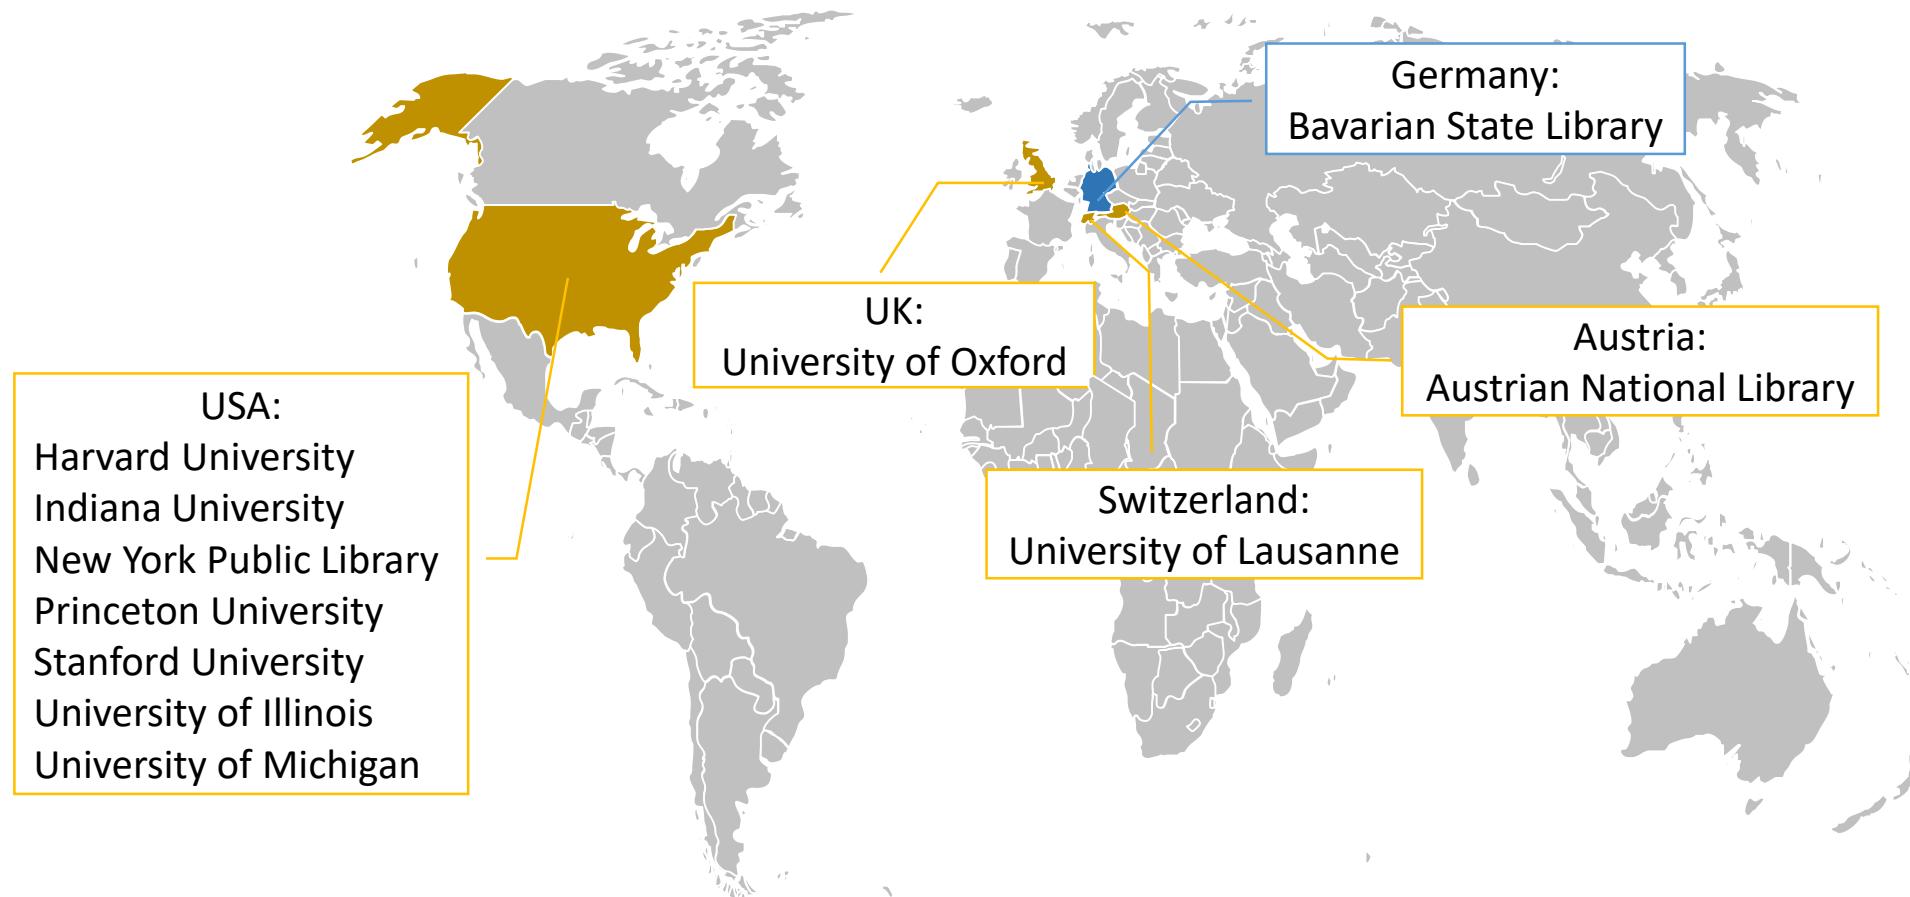
# Scattered Digital Resources of ALZ



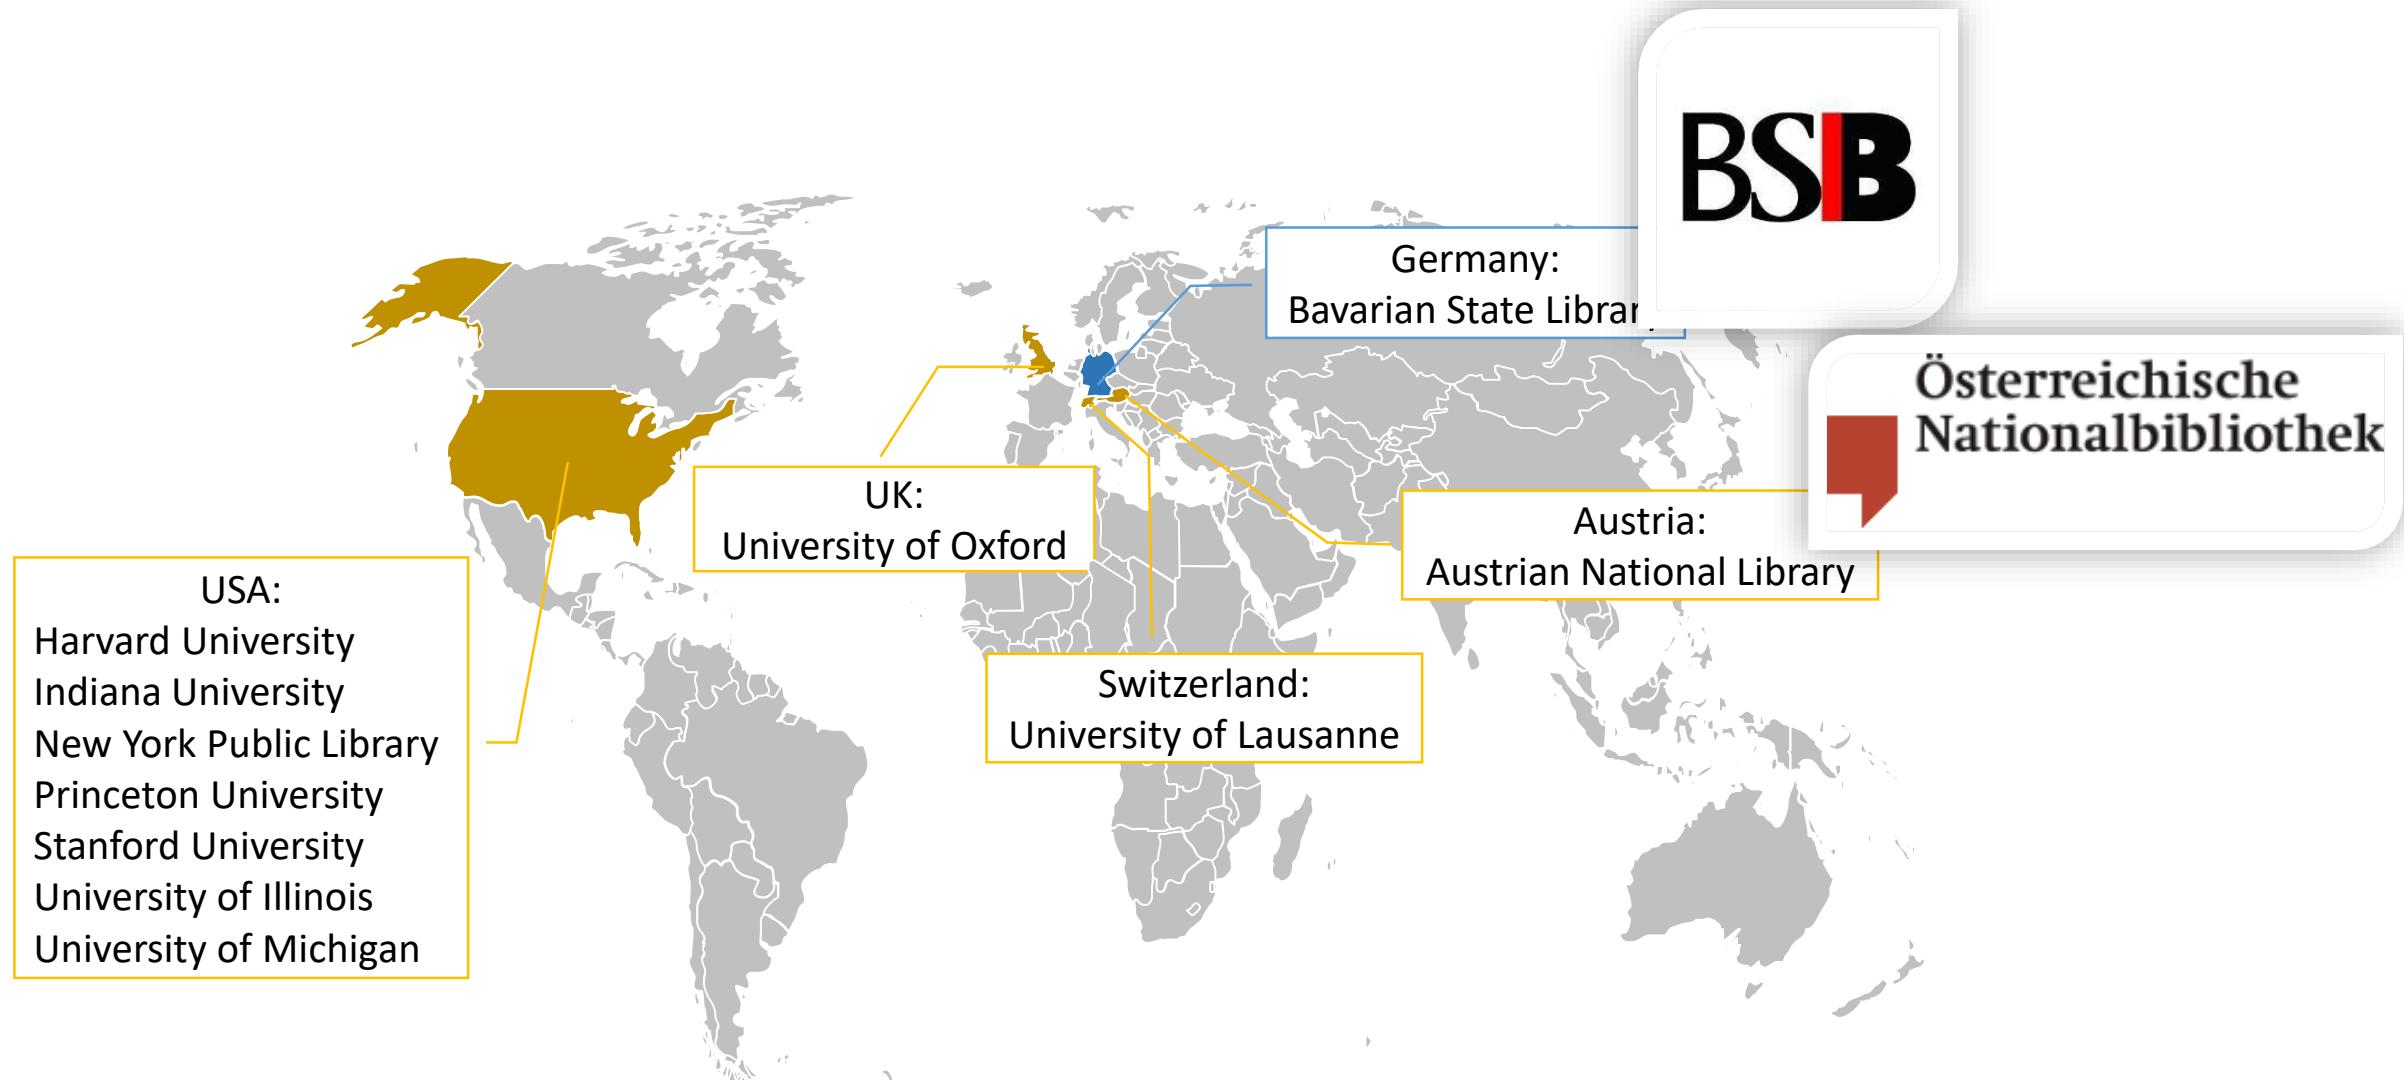
# Scattered Digital Resources of ALZ



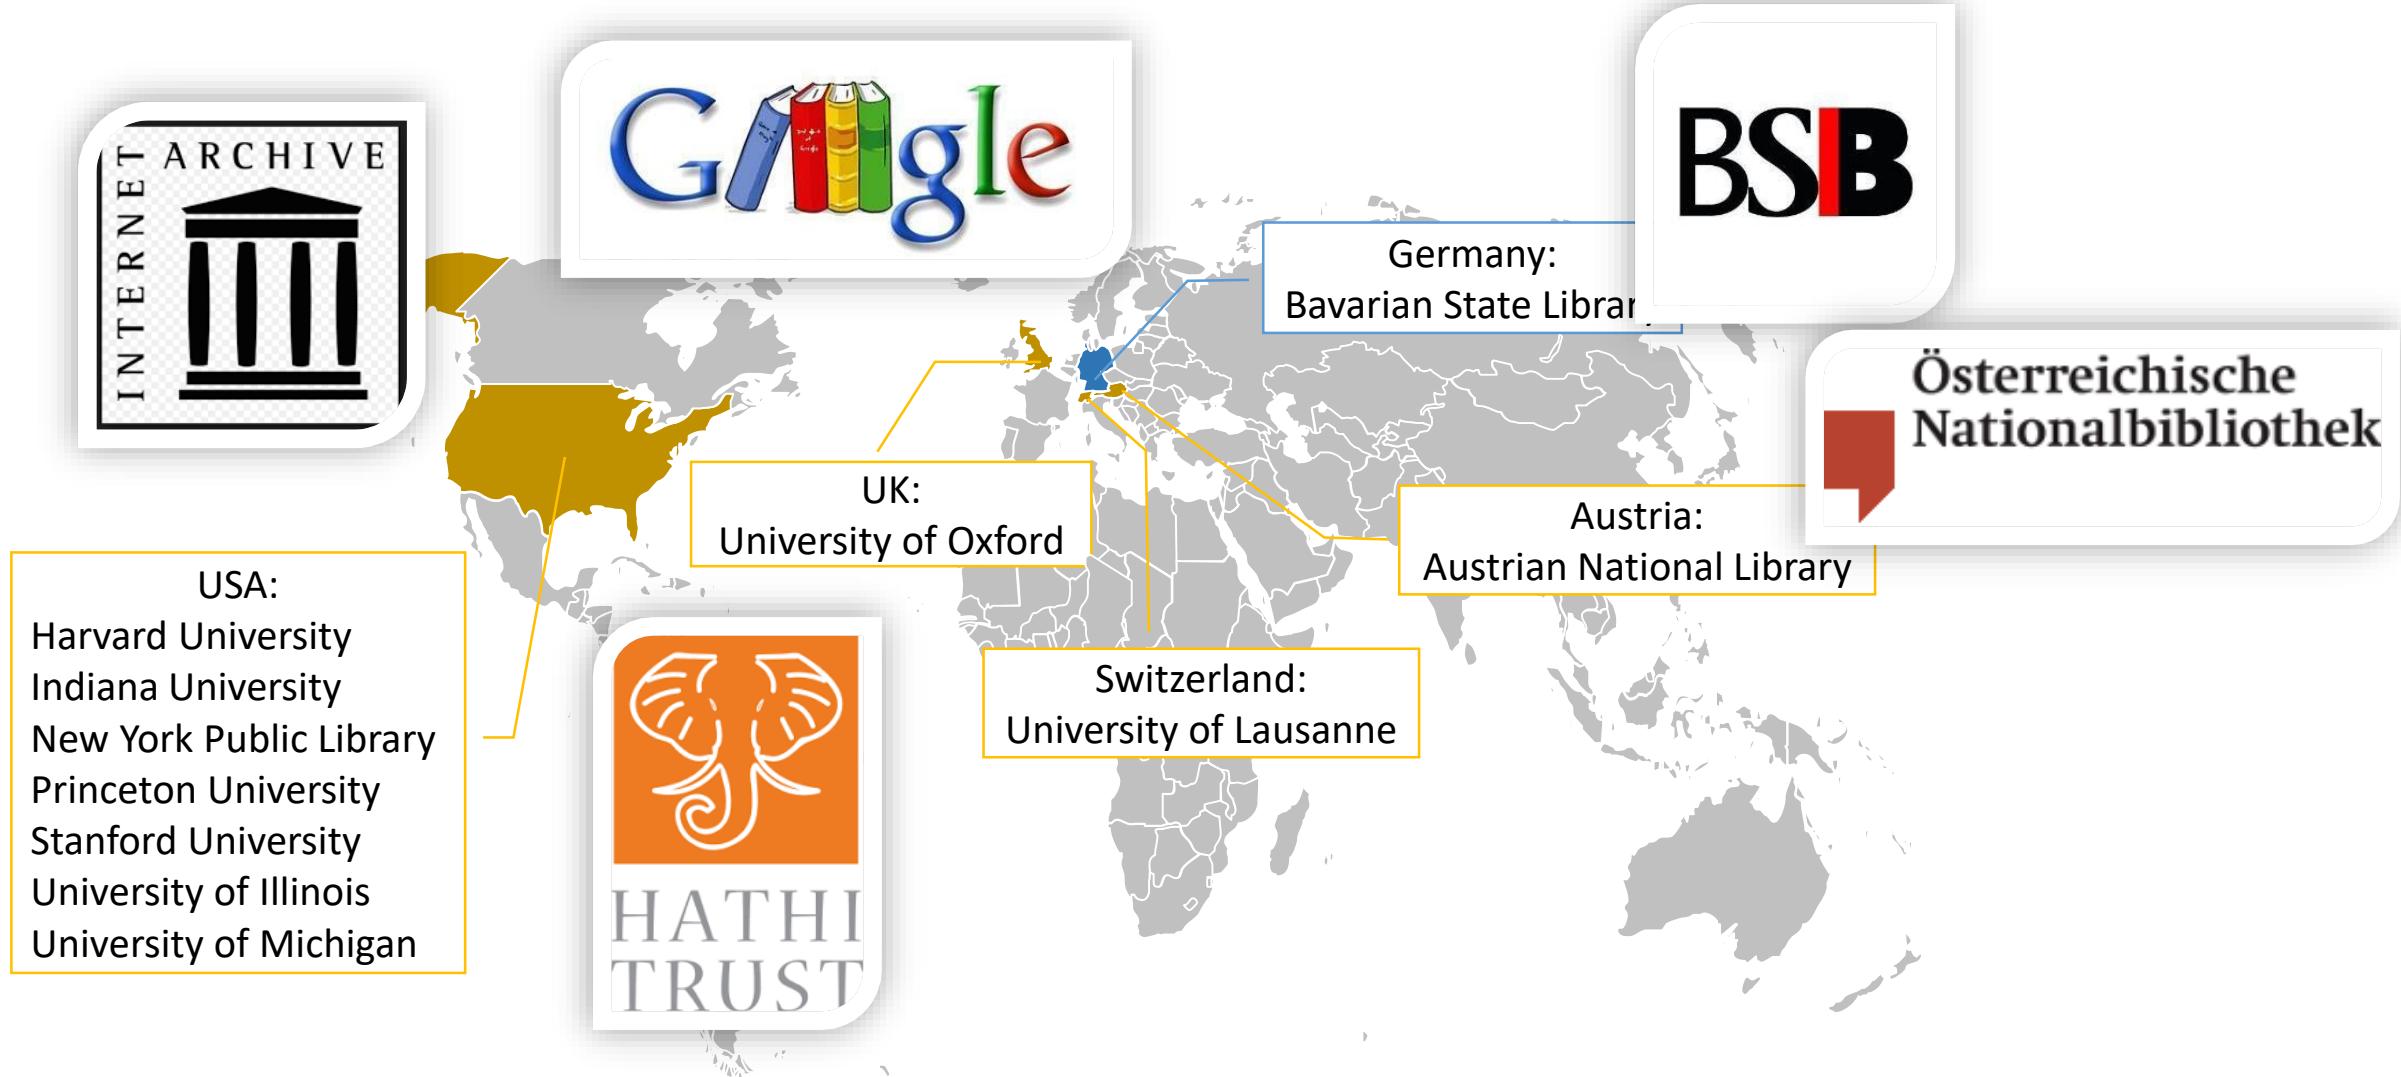
# Scattered Digital Resources of ALZ



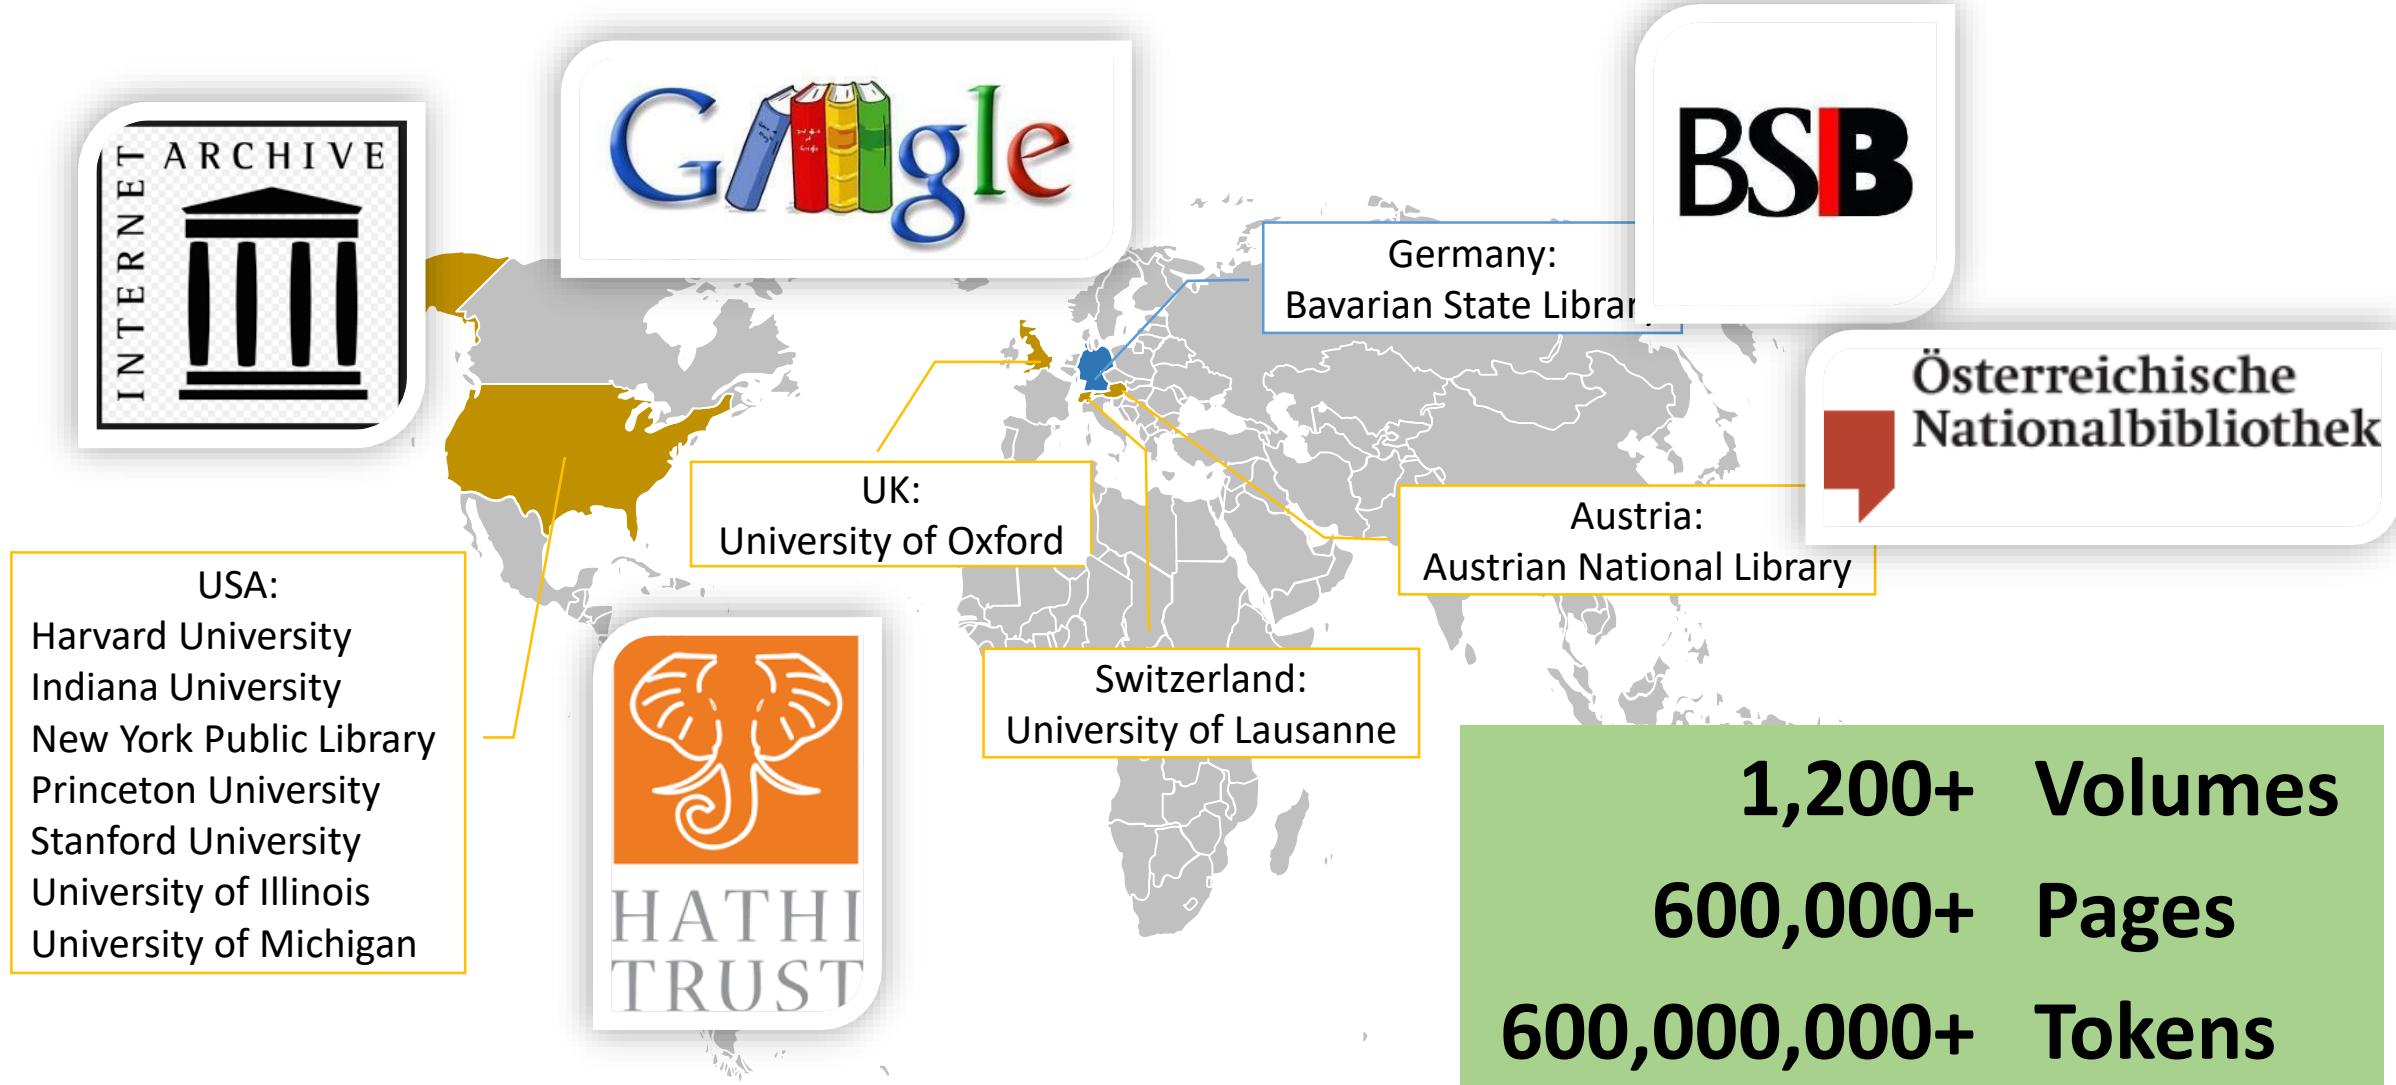
# Scattered Digital Resources of ALZ



# Scattered Digital Resources of ALZ



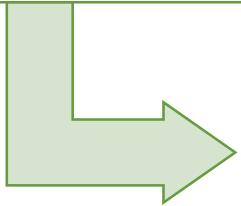
# Scattered Digital Resources of ALZ



# Proposed Workflow

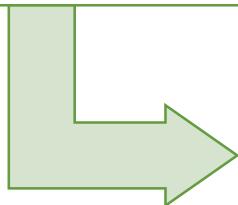
Digital Libraries  
and the Web

- Collect
- Correct Metadata

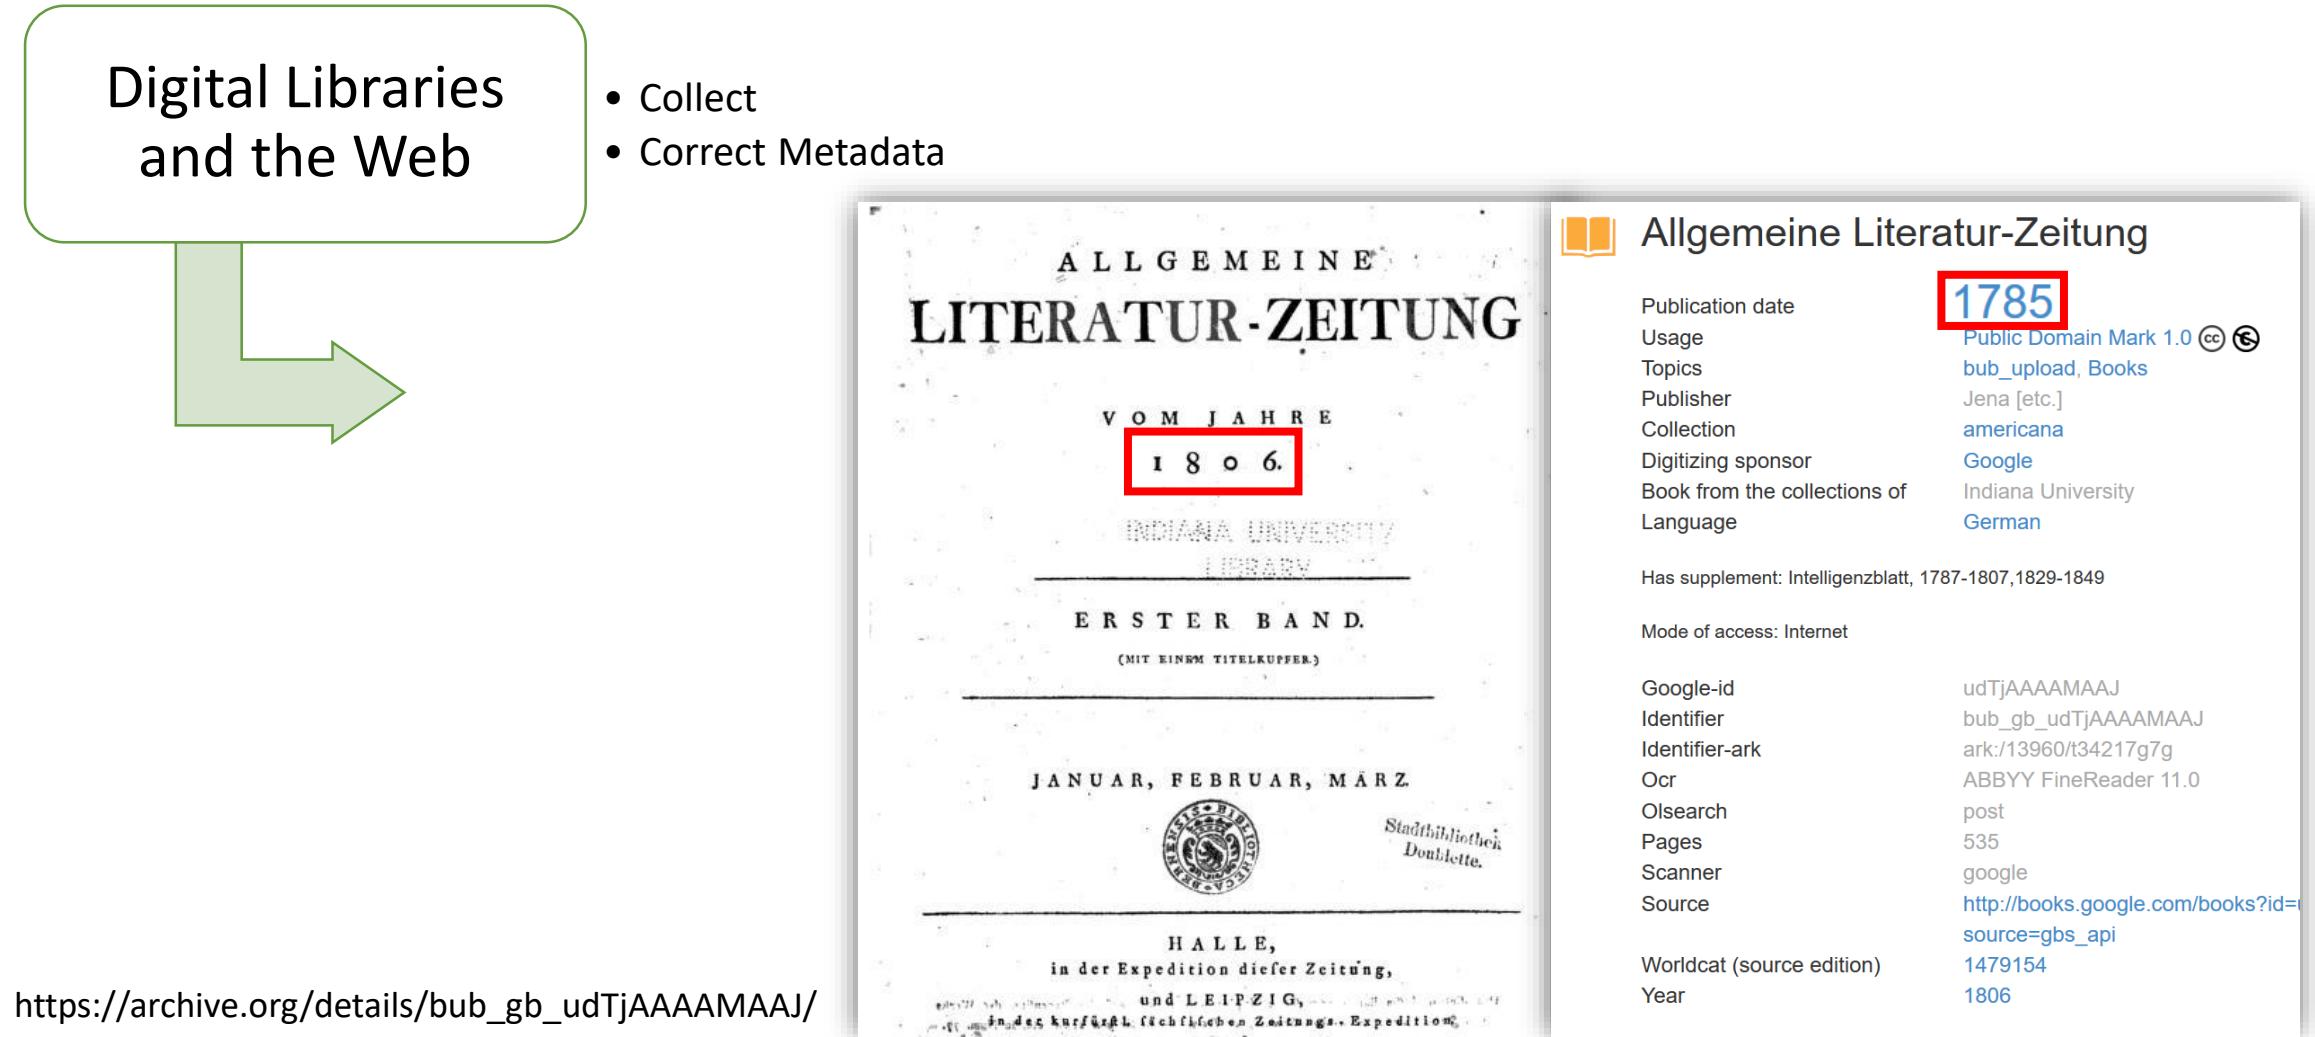


# Proposed Workflow

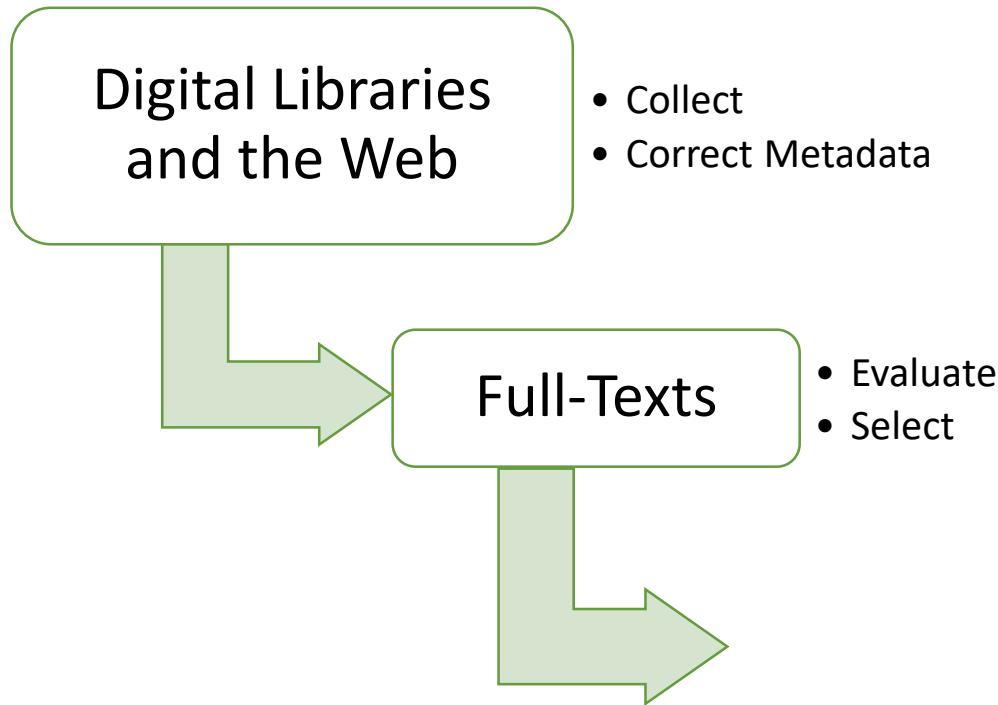
Digital Libraries  
and the Web



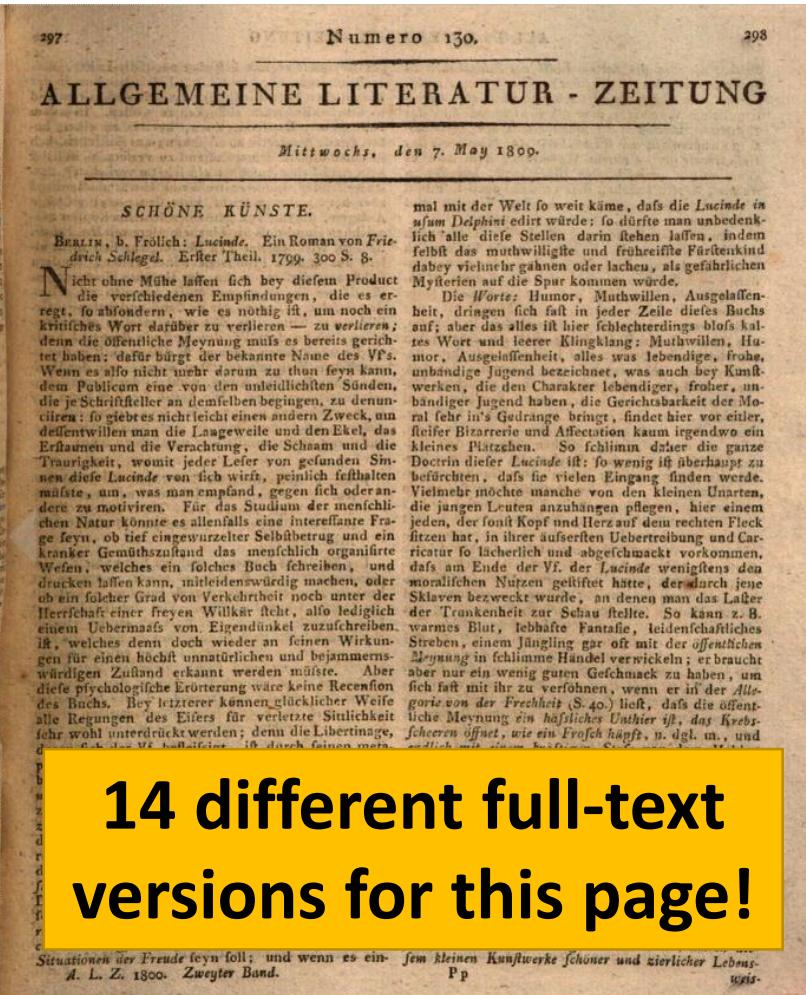
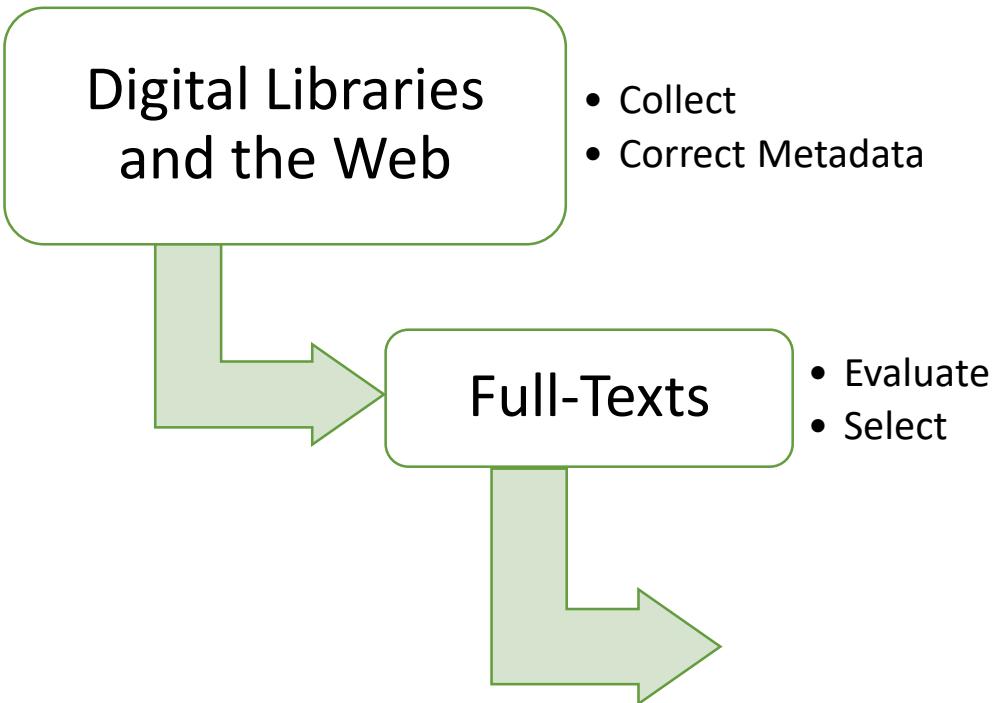
- Collect
- Correct Metadata



# Proposed Workflow

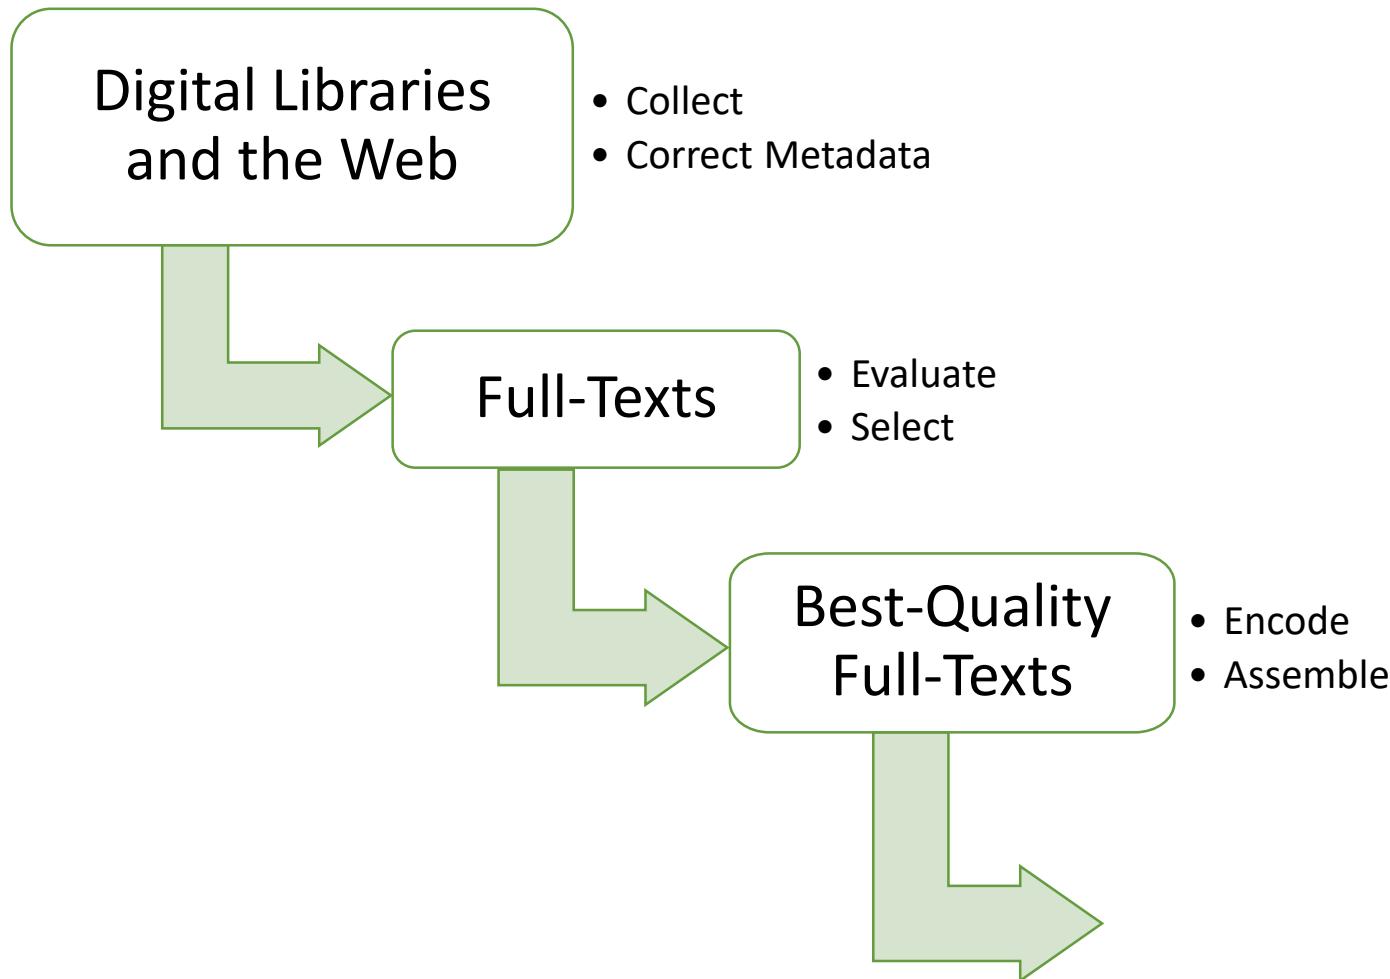


# Proposed Workflow

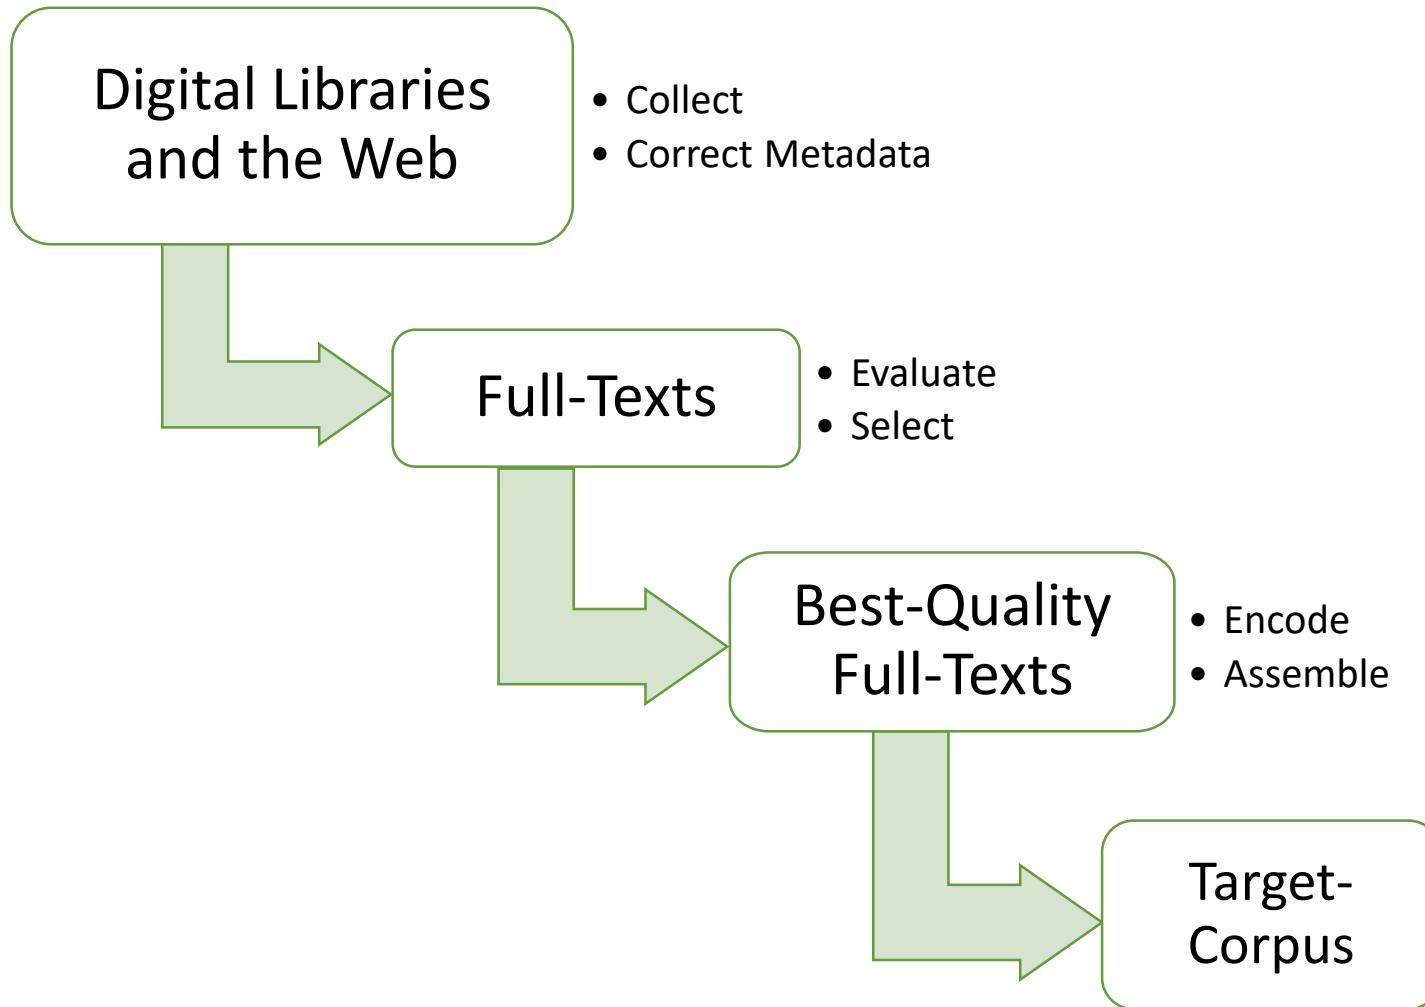


297  
130, 298  
N um e ro  
ALLGEMEINE LITERATUR - ZEITUNG  
Mittwochs,  
den 7. May 1809.  
S C H ÖNE KÜNSTE.  
BERLIN, b. Frölich: *Lucinde*. Ein Roman von Friedr. Schlegel. Erster Theil. 1799. 300 S. 8.  
Wie ohne Mühe lassen sich bey diesem Product die verschiedenen Empfindungen, die es erregt, fo abföndern, wie es nothig ist, um noch ein kritisches Wort darüber zu verlieren — zu verlieren; denn die öffentliche Meynung muß es bereits gerichtet haben; dafür bürgt der bekannte Name des Vfs. Wenn es also nicht mehr darum zu thun feys kann, dem Publicum eine von den unleidlichen Sünden, die Schriftsteller an demselben begingen, zu denunciiren: so giebt es nicht leicht einen andern Zweck, um dessentwegen man die Laageweite und den Ekel, das Erstaunen und die Verachtung, die Scham und die Traurigkeit, womit jeder Lefer von gefundenen Sinnen diese *Lucinde* von sich wirkt, peinlich fühlten müßte, um, was man empfand, gegen sich oder andere zu motivieren. Für das Studium der menschlichen Natur könnte es allenfalls eine interessante Frage seyn, ob tief eingewurzelte Selbstbetrug und ein kranker Gemüthszustand das menschlich organisierte Wesen, welches ein solches Buch schreiben, und drucken läßt, kann, mitleidenswürdig machen, oder ob ein solcher Grad von Verkehrtheit noch unter der Herrschaft einer freyen Willkür steht, also lediglich einen Übermafs von Eigendunkel zuzuschreiben ist, welches denn doch wieder an seinen Wirkungen für einen höchst unnatürlichen und bejammernswürdigen Zustand erkannt werden müßte. Aber diese psychologische Erörterung wäre keine Recension des Buchs. Bey letzterer können glücklicher Weise alle Regungen des Eifers für verletzte Sittlichkeit sehr wohl unterdrückt werden; denn die Libertätage, die wohl unterdrückt werden; denn die Libertätage, deren sich der Vf. befleißigt, ist durch feinen metaphyisch-poetischen Unfini unchäglich gemacht, und bey dem töpelhaften Enthusiasmus (S. 30) der ihm ursprünglich und wesentlich in der Natur des Mannes zu liegen scheint, der, wie er hinzufetzt, leicht bis zur Grobheit göttlich ist, heben sich, zum Glück für die Jugend, die an plumpen oder feurigen Schilderungen der Wolluft ein ichäliches Wohlgefallen finden könnte, die wirkliche Tölpelheit und der fol-damit Enthusiasmus fo ziemlich gegen einander auf Dies gilt felbit von den Ichändlungen, aretinisch feyntafenden Stellen, z. B. von der laubern dithyranibischen Fantasie über die schönte Situation, welche die witzige und schönte unter den Gefalten und Situationen ärer Freude feyn foll; und wenn es ein- A. L. Z. 1800. Zweyter Band.

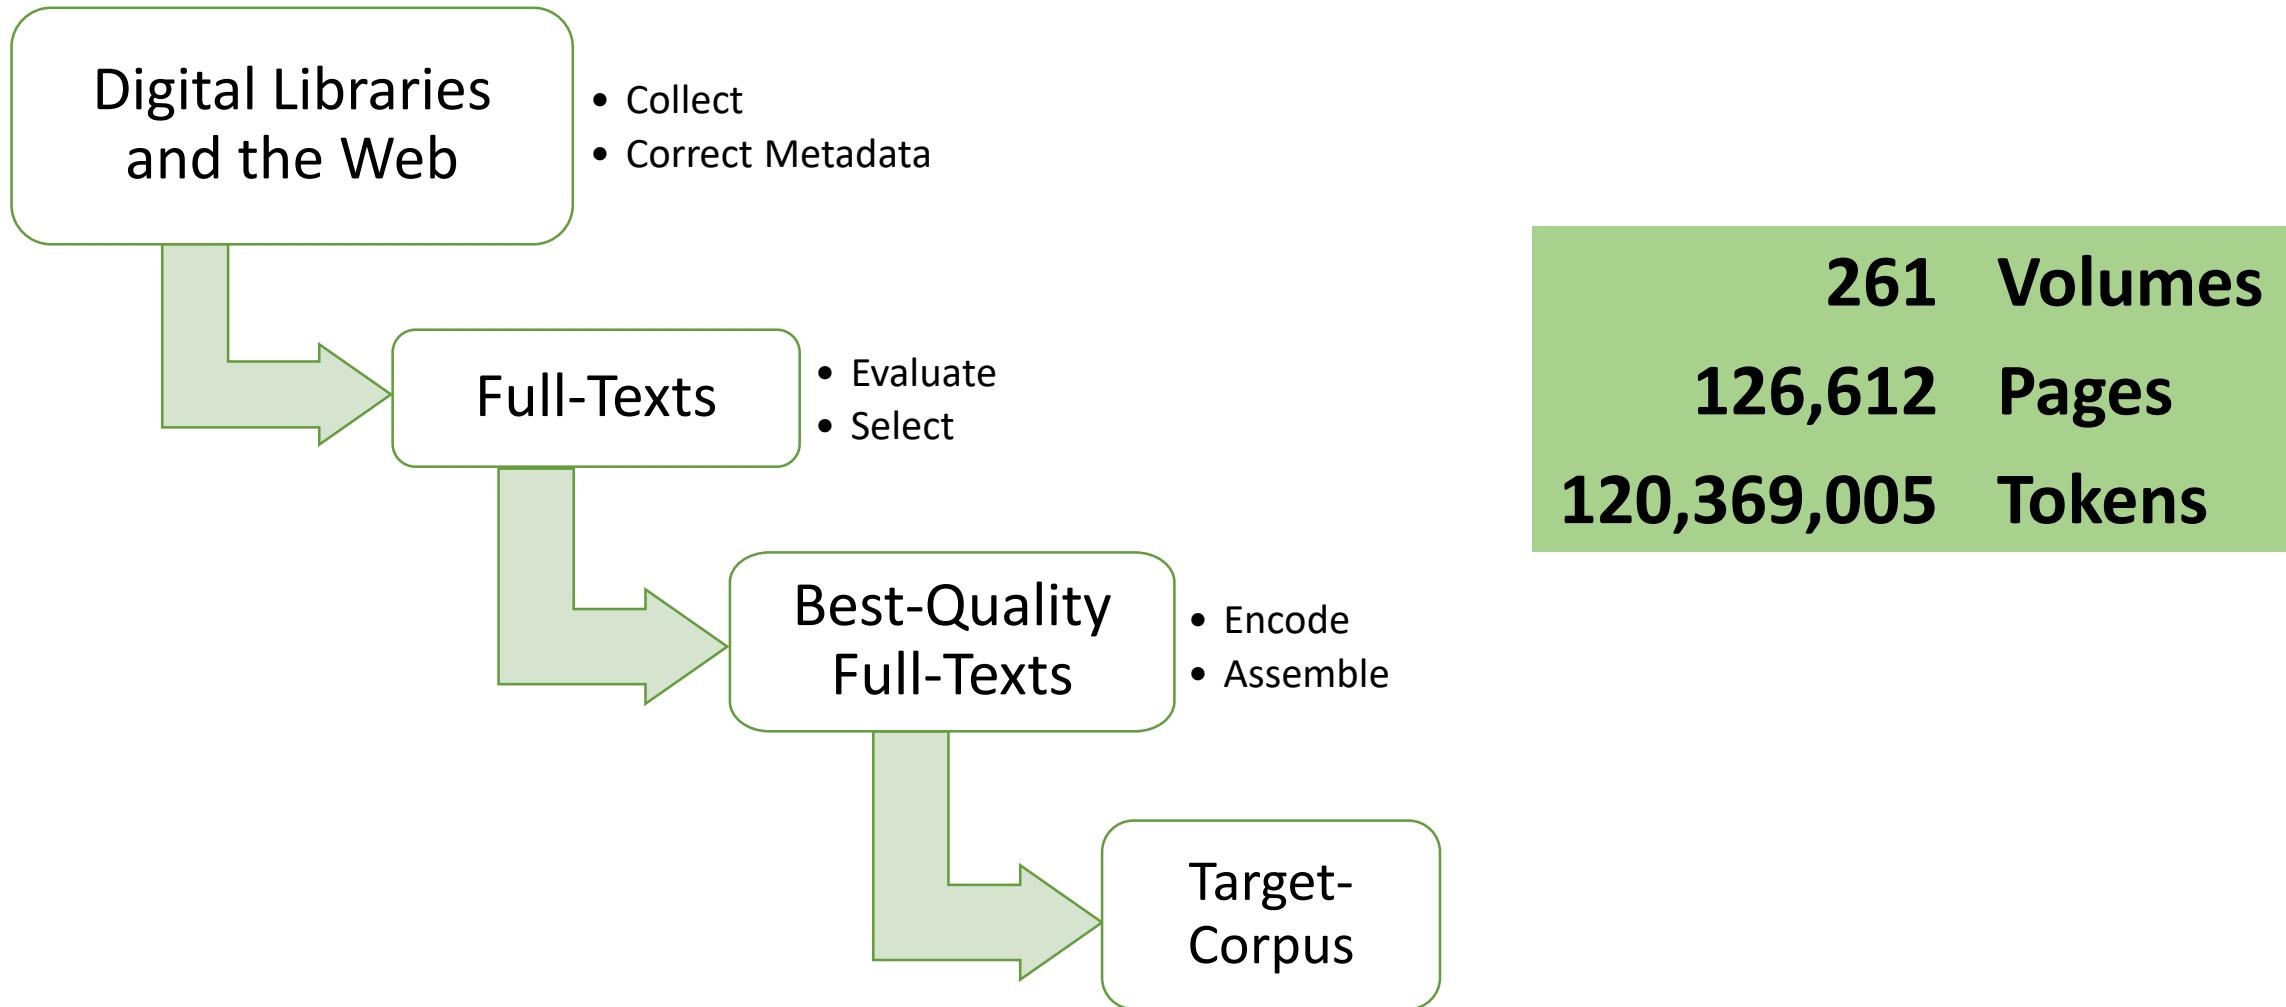
# Proposed Workflow



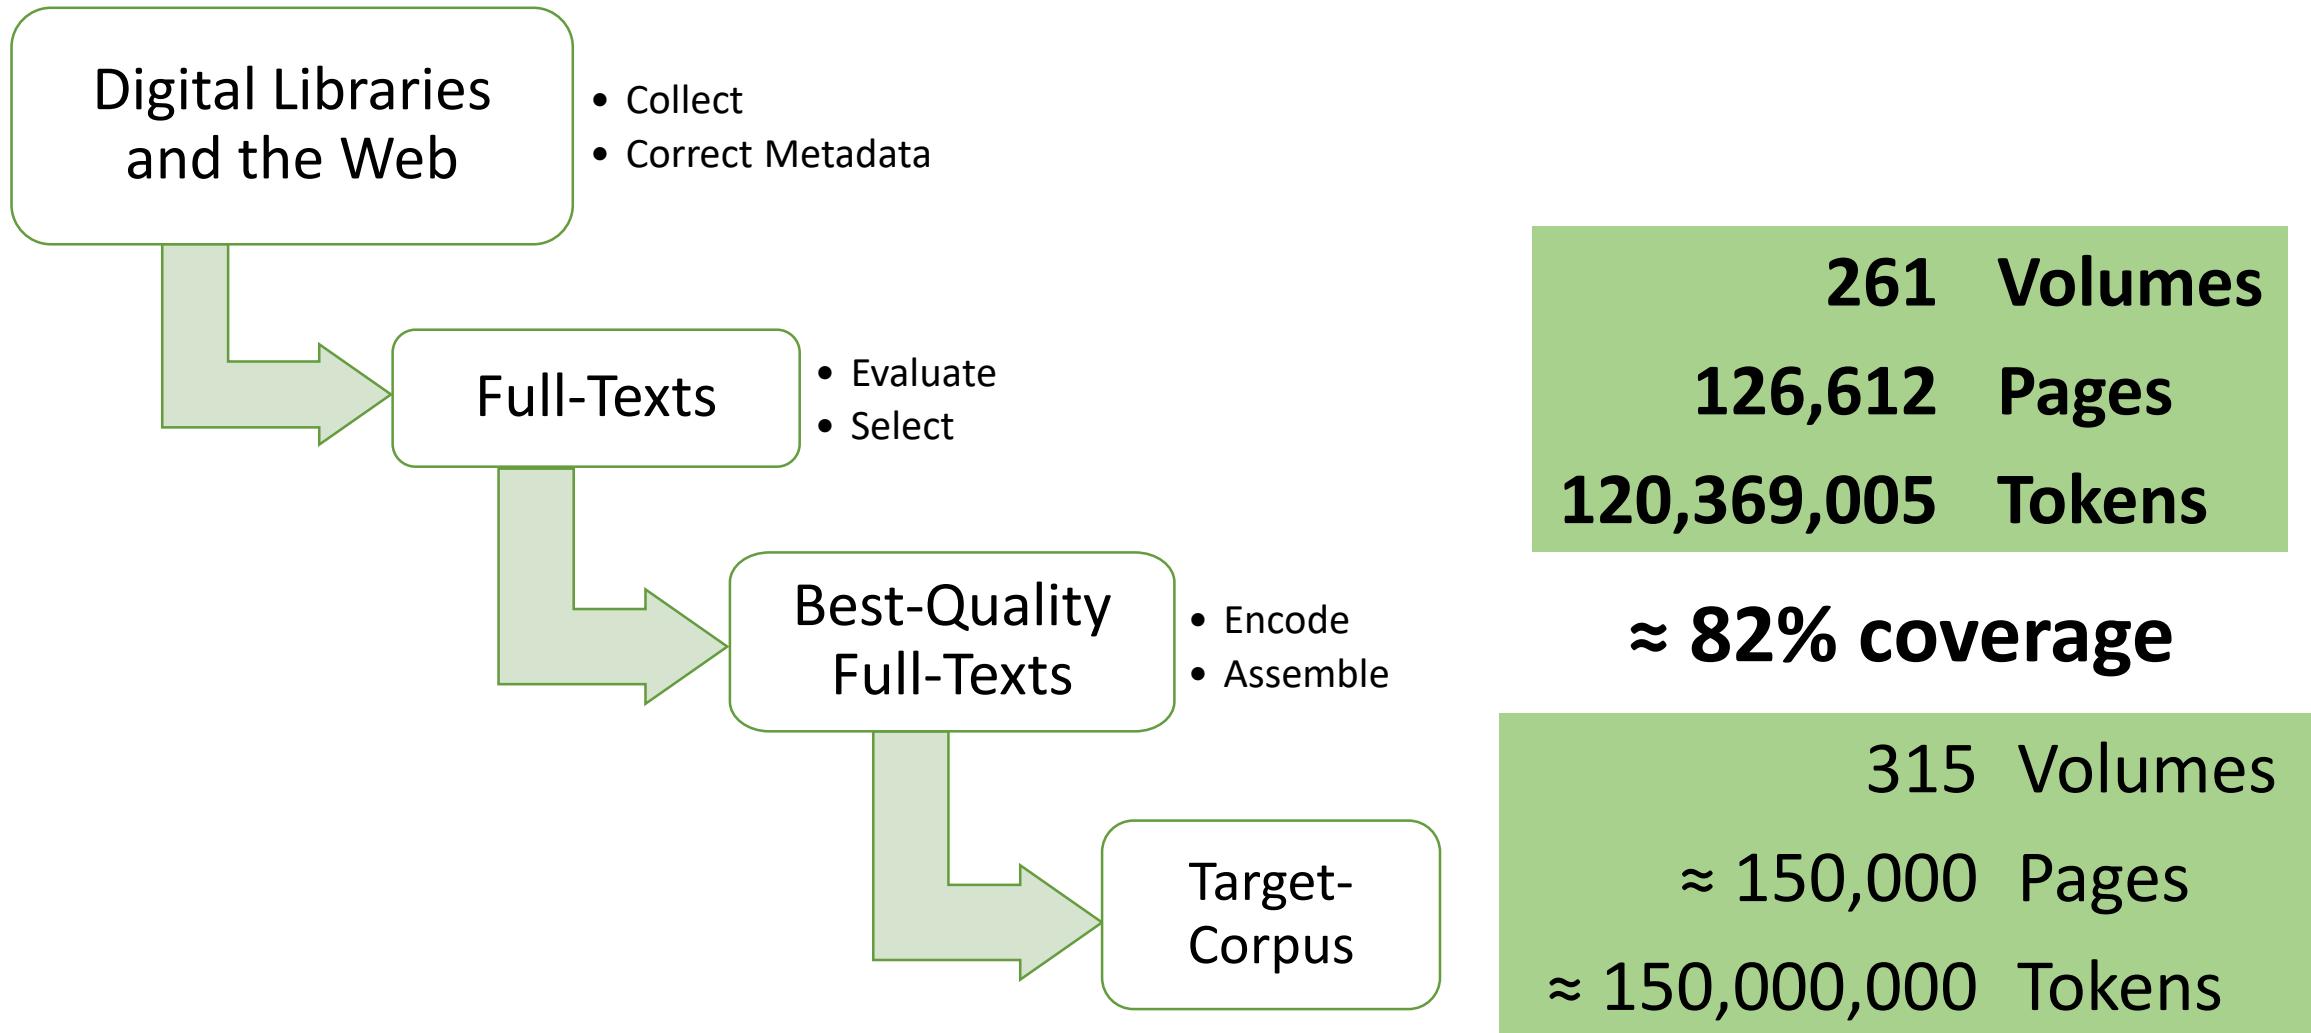
# Proposed Workflow



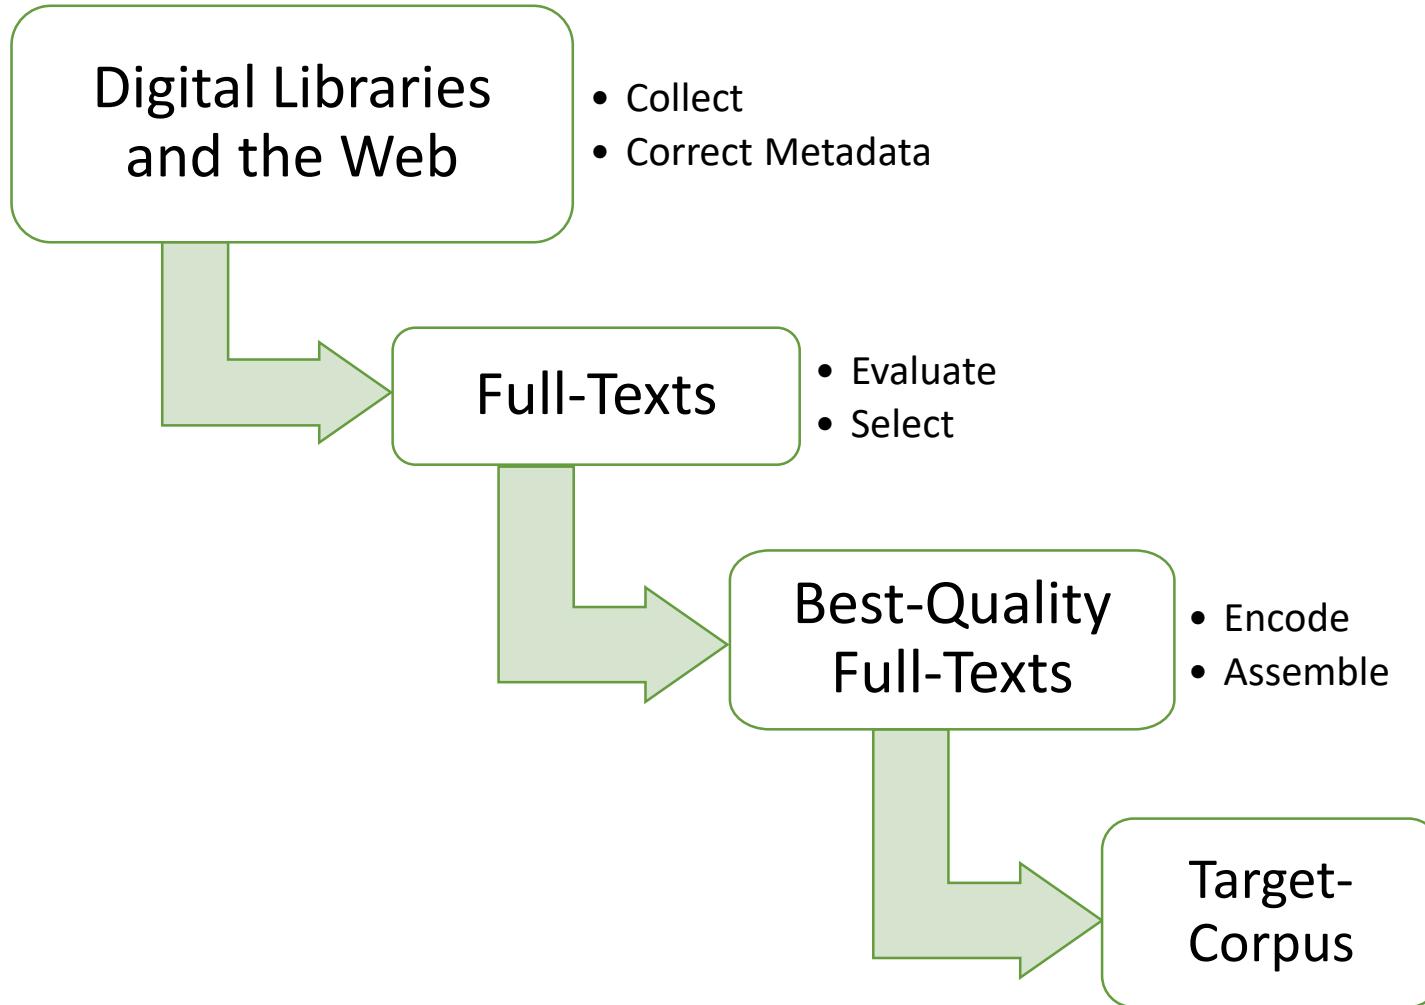
# Result



# Result



# Result



**The Largest Corpus for German Romanticism**  
<https://github.com/JULIELab/ALZ>

**261 Volumes**  
**126,612 Pages**  
**120,369,005 Tokens**

**$\approx 82\%$  coverage**

**315 Volumes**  
 **$\approx 150,000$  Pages**  
 **$\approx 150,000,000$  Tokens**

# Problems

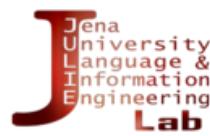
- Restricted Accessibility
- Heterogeneous Digitizing Conditions and OCR-Qualities

# Conclusion

- The Largest Corpus for German Romanticism
- Big Potential of DLs for Computational Literary Studies
- More Cooperation Between DLs Desirable
- Better Metadata and OCR-Quality are Desirable

# Corpus Assembly as Text Data Integration from Digital Libraries and the Web

## Thank you!



Udo Hahn & Tinghui Duan

Jena University Language & Information Engineering (JULIE) Lab

<https://julielab.de/>

DFG Graduate School „Romanticism as a Model“

<http://modellromantik.uni-jena.de>

Friedrich Schiller University Jena, Germany

