

[講演要旨] Text Encoding Initiative ガイドラインに基づく古地震史料のマークアップ[†]

橋本雄太*(京都大学文学研究科)・加納靖之(京都大学防災研究所)・大邑潤三(佛教大学文学研究科)

§ 1. はじめに

古地震史料の研究は百年にわたる蓄積を有する分野であり、これまでに多数の史料が翻刻されてきた。近年はこれらの翻刻データをWeb上で公開する動きも進んでいる。しかしながら、既存の翻刻テキストの多くはプレーンテキスト形式で提供されており、情報の検索や加工に関して難がある。

例えば、史料中に現れる日時や場所に関する情報をピックアップするためには、人間が翻刻テキストの全文に目を通さなければならぬ。古文書の読解に不慣れな研究者にとって、この作業は大きな負荷となる。地震史料からの効率的な情報抽出を可能にするためには、翻刻テキストが何らかの機械処理可能なフォーマットで記述されていることが望ましい。

§ 2. Text Encoding Initiative (TEI)

本研究の目的は、人文学テキストの電子化フォーマットであるText Encoding Initiative (TEI) ガイドライン[1]にもとづいて、古地震史料の翻刻テキストを機械可読な形式で記述する手法を開発することである。TEIは、1980年代から欧州のアーキビストを中心に策定され、デジタル人文学(digital humanities)分野では人文学のテキストを電子化する際の国際標準フォーマットとして流通している。

TEIの特徴は、対象文書を汎用マークアップ言語のXML (eXtensible Markup Language) で記述することにある。TEI ガイドラインには、日時や場所など、テキスト中の特定要素をマークアップするための数百種類の XML タグや属性(attribute)が定義されており、これらを利用することで、翻刻テキストを構造化して記述することが可能になる。

§ 3. 『信越震漲録』翻刻テキストのTEI化

発表者らは、TEIの試験的な地震史料への適用として、『信越震漲録』の翻刻テキストをTEI化する作業を実施している。『信越震漲録』は、弘化4年(1847)に発生した善光寺地震の記録文書である。内容は信濃及び越後の藩、代官所から幕府側に送られた届書が大部分を占めている。発表者らが所属する京都大学古地震研究会では、『信越震漲録』を含む善光寺地震に関わる数点の史料を翻刻してきた[2]。

図1は、TEI ガイドラインにしたがって記述した同史料の一節である。本研究では、TEI が提供する次のようなタグを利用して翻刻テキストをマークアップした：

- <div>: 届書全体
- <date>: 日時に関する記述
- <seg>: 地震被害に関する記述
- <placeName>: 場所名

さらに、具体的な日時情報や地震の被害種類をXML タグの属性に記述している。

```
<div type="section">
  <head>○<date when="1847-05-15">四月朔日</date> 御届</head>
  <p>一 私在所<placeName>信州松代</placeName>
    <date when="1847-05-08T22:00:00">一昨廿四日亥刻頃</date>
    より大地震ニ而、
    <seg type="damage" subtype="building">
      城内住居向横井田塚等夥敷破損、
      家中屋敷城下町領分村々其外支配所漸家数多、
      死失人夥舗、
    </seg>
    <seg type="damage" subtype="fire">
      残ニ村方ニ出火も有之
    </seg>
    <seg type="damage" subtype="landslide">
      其上山中山抜崩、<geogName type="river">犀川</geogName>へ
      押埋水塔(湛)追々致充满、勿論流水一切無之、北国往還
      <placeName>丹波島宿</placeName>渡船場干上リニ相成、此上
      右溢水押出方ニ寄如何様之変地も難斗奉存候
    </seg>
    只今以折々相震申候、
    委細之義者追而可申上候得共此段御届申上候、以上
  </p>
</div>
```

図 1 TEI を用いて記述した『信越震漲録』の一節

このように翻刻テキストをフォーマットしておくことで、史料から機械的に情報を抽出することが可能になる。例えば、火災被害に関する記述を一括取得するようなプログラムは、Ruby や Python などのプログラミング言語を利用すれば数行で記述可能である。さらに、取得した情報を場所情報や時間情報とリンクさせることにより、様々な分析が可能になる。

§ 4. まとめと今後の展望

本稿では、TEI を利用して地震史料をマークアップする手法を紹介した。発表者らは、TEI で記述した地震史料から、被害マップや時系列表を自動生成するためのプログラムを開発している。

参考文献・URL

- [1] Text Encoding Initiative, <http://www.tei-c.org/>
- [2] 五島敏芳ほか(2013) :弘化四年(1847)善光寺地震について、京都大学防災研究所年報、第 56 号 B

謝辞

本研究は、平成27年度京都大学防災研究所萌芽的共同研究(課題番号 27H-03)の助成を受けたものです。