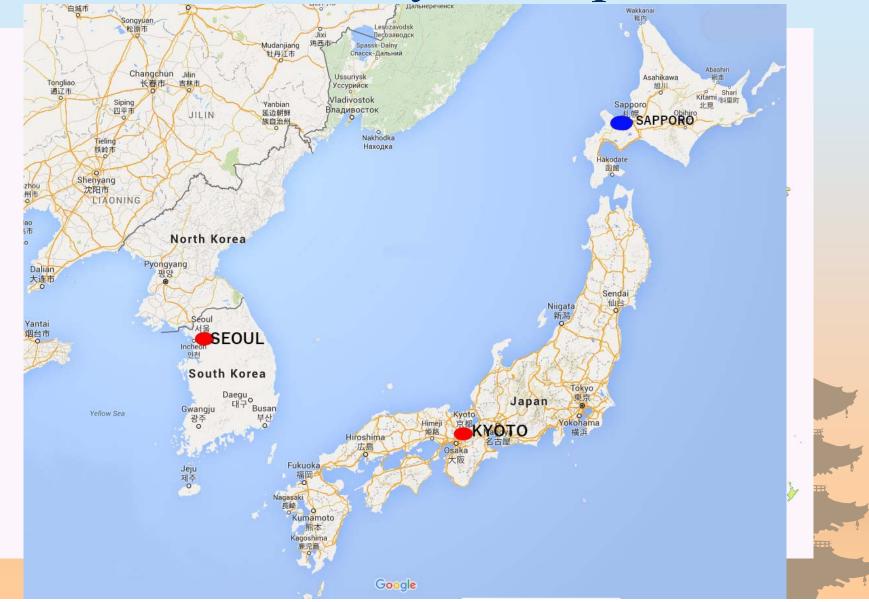
### **JATS XML for Japanese language**

The 3<sup>rd</sup> Asian Science Editors' Conference and Workshop 2016

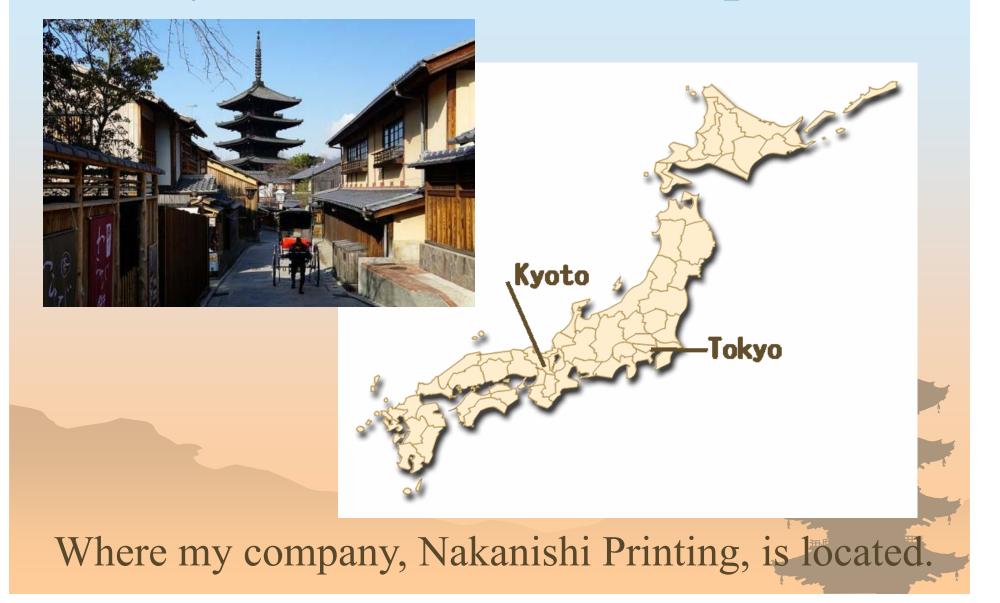
Hidehiko Nakanishi Ph.D.

Nakanishi Printing Co., Ltd. Kyoto Japan

# I am from Kyoto, Japan



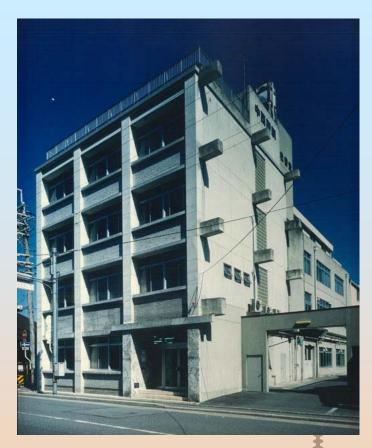
## Kyoto was a former capital



### Our Tradition

Former building of Nakanishi Printing in Taisho era (1912-1926)





Current building of Nakanishi printing Founded in 1865 by our ancestor. 150 year old family business. One of the oldest printers.

# Our history



A brazier made by Woodcut print plate in 19c



Type picker 1960's





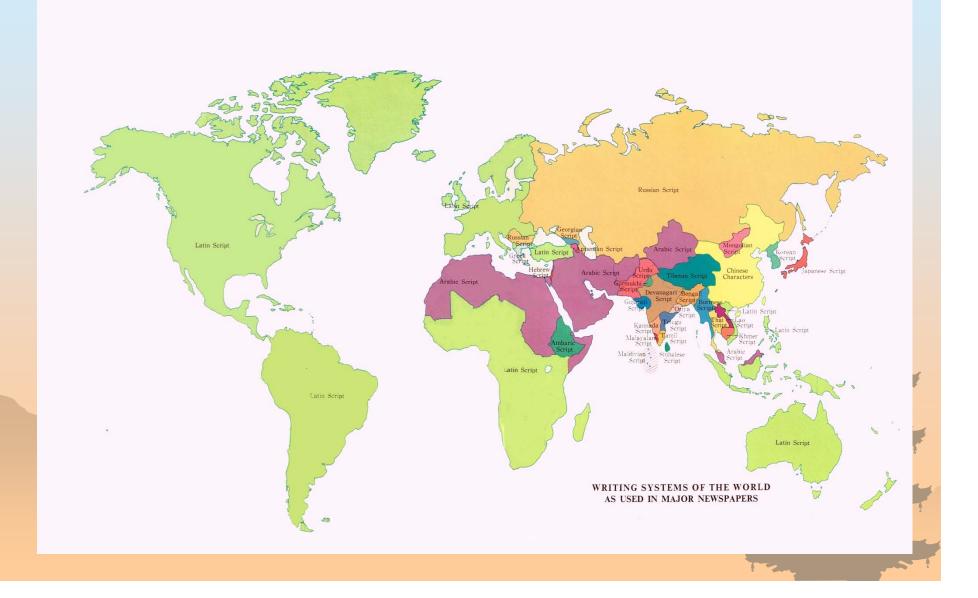
## Contents

- **1.** Introduction
- 2. JATS adoption in Japanese XML expression
- **3.** Creating Japanese XML articles in JATS
- 4. Creating PDF using AH Formatter
- 5. Challenges of Applying JATS to Japanese language texts
- 6. Future
- 7. Conclusion

# Introduction



### Many countries use Non-Latin script

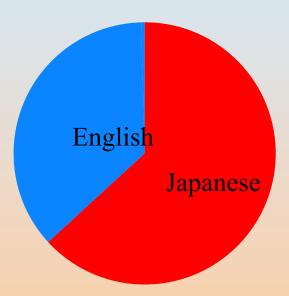


# Not all research articles are written in English.

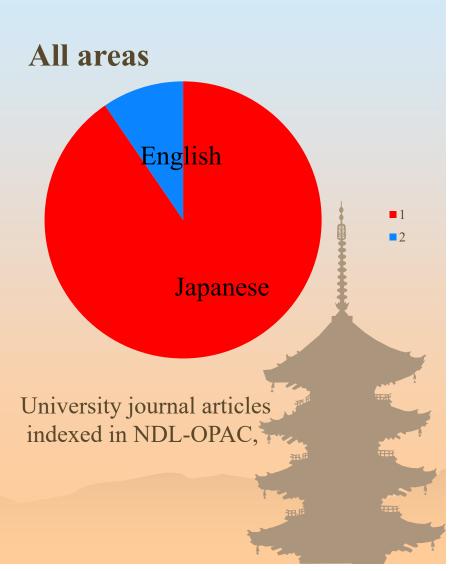
### Many articles don't even use the Latin alphabets

### What languages are used in articles written in Japan?

**STM** 



Articles published in J-Stage, E-journal platform operated by the Japan Science and Technology Agency (JST).



# The importance of articles in native tongue

- English is the world's common language.
- But there are many merits of describing and reading in one's native tongue.



# The change of world common language

### English

- As natural language, common language especially in STM domain.
- The evolution of translation software will change this positon.

### • XML

- Becoming the world common language.
- Prescribing common structure →Common understanding

12

The importance of the XML in the native tongue

Common structured articles in the native language →XML in the native language.

So far English was thought to be essential for XML description, now it is not!

XML articles in Japanese is ideal.
We need suitable schema.

# JATS adoption in Japanese XML expression

# We wanted schema applicable to Japanese

 Even for Japanese-language articles, e-articles are essential.

 We were looking for schema for Japaneselanguage articles.

Such schema had to accept English as well.

## JATS multi-language support

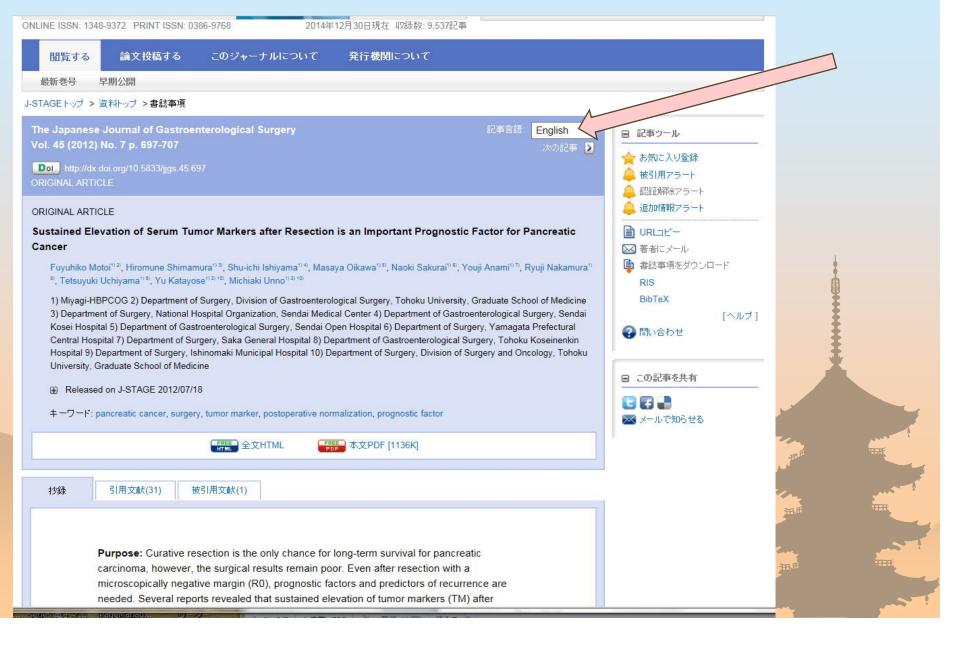
 In 2011 JATS 0.4 enabled to express Japaneselanguage articles in XML.

 J-STAGE supported JATS 0.4 immediately
 We started creating JATS XML for Japanese-language articles.

## This is a Japanese e-journal

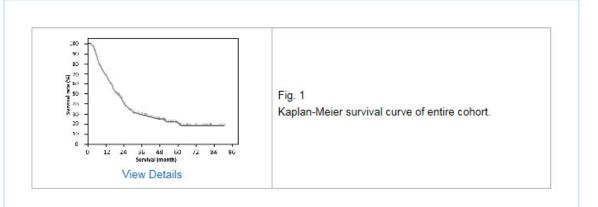
JySTAGE         My J-STAGEとは?         ログイン         新規登録         ショッピングカート         イ	ヘルブ   Japanese > English
日本消化器外科学会雑誌 The Japanese Journal of Gastroenterological Surgery ONLINE ISSN: 1348-9372 PRINT ISSN: 0386-9768 2014年12月30日現在 収録数: 9,537記事	OI 検索 詳細検索
閲覧する         論文投稿する         このジャーナルについて         発行機関について           最新巻号         早期公開             J-STAGE トップ > 資料トップ > 全文HTML	
日本消化器外科学会雑誌 記事言語: Japanese ✓ Vol. 45 (2012) No. 7 p. 697-707 Dol http://dx.doi.org/10.5833/jjgs.45.697 原著	<ul> <li>□ 記事ツール</li> <li>☆ お気に入り登録</li> <li>☆ 被引用アラート</li> <li>認証料除アラート</li> <li>追加r情報アラート</li> </ul>
全文         図表(6)         引用文献(31)         被引用文献(1)           原着 <b>膵臓癌切除後腫瘍マーカー非正常化は重要な予後因子である</b> 元井 冬彦 <sup>112</sup> , 島村 弘宗 <sup>113</sup> , 石山 秀一 <sup>116</sup> , 及川 昌也 <sup>116</sup> , 桜井 直樹 <sup>116</sup> , 阿南 陽二 <sup>117</sup> , 中村 隆司 <sup>116</sup> , 内山 哲之 <sup>119</sup> , 片寄 友 <sup>11216</sup> , 海野 倫明 <sup>11216</sup> 1)宮城肝胆膵癌化学療法研究会 2)東北大学大学院消化器外科 3)国立病院機構仙台医療センター外科 4) 仙台厚生病院消化器外科 5) 仙台 オープン病院消化器外科 6) 山形県立中央病院外科 7) 坂総合病院外科 8) 東北厚生年金病院消化器外科 9) 石巻市立病院外科 10) 東北大学大	<ul> <li>■ URL⊐ビー</li> <li>■ 著話車項をダウンロード</li> <li>RIS</li> <li>BibTeX</li> </ul>
● J-STAGE公開日 2012/07/18 ● T-STAGE公開日 2012/07/18 ● 本文PDF [1136K]	<ul> <li>② 問い合わせ</li> <li>■ この記事を共有</li> </ul>
Index ▼ Abstract ▼ はじめに ▼ 対象と方法 ▼ 結果 The Japanese Journa	L of Castroenterological Surgery
	al of Gastroenterological Surgery

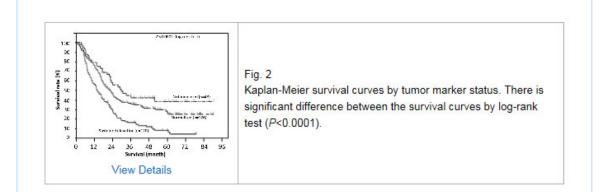
### Same page expressed in English



### 3. 切除後腫瘍マーカーによる生存期間の比較

294例の生存曲線を, Fig. 1に示す.生存期間中央値は684日で,5年全生存率は24.4%であった.3群で生存曲線を比較す ると,各群の1,3,5年全生存率は,非上昇群で84.8,48.0,43.6%,正常化群で78.9,42.0,31.7%,非正常化群で61.6, 18.4,9.0%であり,生存期間中央値は,非上昇群で1,092日,正常化群で736日,非正常化群で505日であった.非正常化群 で,有意に生存期間が短く,予後不良であった(Fig. 2, P<0.0001, log-rank test).





### 4. 多変量解析による予後因子の抽出

年齢・性・術前腫瘍マーカー・術式・進行度・組織型・癌遺残度・術後腫瘍マーカー・術後補助療法の各因子で、Cox比例ハ ザードモデルを用い解析した・単変量解析では,術前腫瘍マーカー(CA19-9上昇>非上昇例),術式(膵全摘>膵頭切除),進 行度(stage 4> stage 3かつstage 1-2> stage 3),癌遺残(R1-2>R0),術後腫瘍マーカー(非正常化>非上昇例)が有意な 予後因子として抽出された。それら単変量解析で有意であった因子を用いて多変量解析を行うと,進行度,術後腫瘍マーカー が有意な予後規定因子として選別された(Table 3).



## Expressing Multiple Languages

- Alternate expressions for a single object are necessary
- Simple repetition of a tag can be confusing
  - Two name expressions of the same person?
  - Or two different persons?
- JATS introduced "alternatives" tags for such cases

## "Alternatives" Tags

• Two name expressions of a single person

```
<name-alternatives>
<name name-style="eastern" xml:lang="ja-Jpan">
<surname>中西</surname>
<given-name>秀彦</given-name>
</name>
<name name-style="western" xml;lang="en">
<surname>Nakanishi</surname>
<given-name>Hidehiko</given-name>
</name>
</name>
</name>
```

### "Alternatives" tags

### <contrib-group>

- <contrib contrib-type="author" xmlns:xlink="http://www.w3.org/1999/xlink" xlink:type="simple">
- <name-alternatives>
- <name name-style="eastern" xml:lang="ja-Jpan">
  - <surname>元井</surname>
  - <given-names>冬彦</given-names>
  - </name>
- <name name-style="western" xml:lang="en">
  - <surname>Motoi</surname>
  - <given-names>Fuyuhiko</given-names>

</name>

- </name-alternatives> <xref ref-type="aff" rid="aff1">1)</xref>
- <xref ref-type="aff" nd="aff2">2)</xref>

### </contrib>

- <contrib contrib-type="author" xmlns:xlink='http://www.w3.org/1999/xlink" xlink:type="simple">
- <name-alternatives>
- <name name-style="eastern" xml:lang="ja-Jpan">
- <surname>島村</sumame> <given-names>弘宗</given-names>
- </name>
- <name name-style="western" xml:lang="en"> <surname>Shim am ura </surname> <giv en-names>Hirom une </giv en-names> </name>
- </name-alternatives>
- </ref ref-type="aff" id="aff1">1)</xref>
- <xref ref-type="aff" rid="aff3">3)</xref>

### </contrib>

- <contrib contrib-type="author" xmlns:xlink="http://www.w3.org/1999/xlink" xlink:type="simple">

- <name-alternatives>
  - <name name-style="eastern" xml:lang="ja-Jpan"> <surname>石山</surname>
    - <given-names>75- </given-names>

### </name>

- <name name-style="western" xml:lang="en">
- <surname>Ishiyama</sumame>
- <given-names>Shu-ichi</given-names>

</name>

- </name-alternatives>
- <xref ref-type="aff" rid="aff1">1)</xref>
- <xref ref-type="aff" nd="aff4">4)</xref>
- </contrib>

# How multiple language can be expressed in JATS

element name	multi-language tag	Note
article title	<trans-title></trans-title>	
article subtitle	<trans-subtitle></trans-subtitle>	
names	<name-alternatives></name-alternatives>	
affiliations	<aff-alternatives></aff-alternatives>	
collaborators	<collab-alternatives></collab-alternatives>	
abstract	<abstract></abstract>	<abstract> is repeatable with different "xml:lang". <trans-abstract> is for articles later translated.</trans-abstract></abstract>
keyword group	<kwd-group></kwd-group>	<kwd-group> is repeatable with different "xml:lang".</kwd-group>
generic	<alternatives></alternatives>	any component which need multi- language data

# The proposal from Japan

 It is not enough to describe Japanese only by multiple language expansion of JATS

 XSPA propose some new elements for JATS standing committee. Some of them were adopted in JATS1.1

- era elements
- ruby elements

### era elements

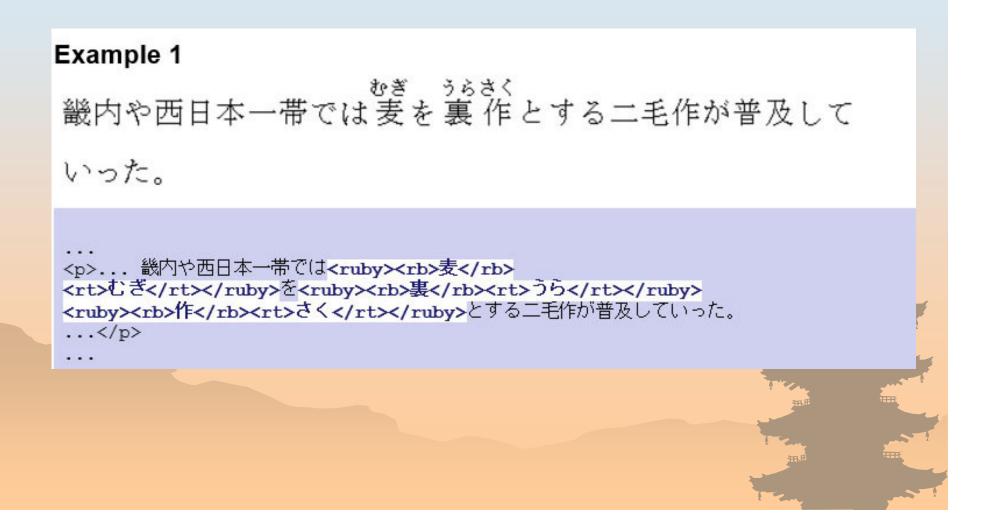
### Example

```
<date date-type="received" calendar="Japanese"
iso-8601-date="1947-07-01">
<day>1</day>
<month>7</day>
<month>7</month>
<year>22</year>
<era>昭和</era>
</date>
```

. . .



## ruby element



# **Creating Japanese XML** articles in JATS

## Creating XML articles in JATS

 We don't have tools readily available for creating Japanese XML files.

### Our method

- 1. Convert Microsoft Word to Microsoft Office Open XML
- 2. Convert Microsoft Office Open XML to JATS XML
- 3. Validate XML

### (1) Converting Microsoft Word to Microsoft Office Open XML

1 xml version="1.0" encoding="U</th <th>TF-8″standalone=″yes″?&gt;</th> <th></th>	TF-8″standalone=″yes″?>	
2 mso-application progid="Word.</p	Document"?>	
<pre>3 <w:worddocument td="" urn:schemas-microsof<="" xmlns:w="http://&lt;/pre&gt;&lt;/td&gt;&lt;td&gt;/schemas.microsoft.com/office/word/2003/wordml″xmlns:v=″urn:schemas-microsoft-com:vml″&lt;/td&gt;&lt;td&gt;&lt;/td&gt;&lt;/tr&gt;&lt;tr&gt;&lt;td&gt;xmlns:w10="><td>t-com:office:word" xmlns:sl="http://schemas.microsoft.com/schemaLibrary/2003/core"</td><td></td></w:worddocument></pre>	t-com:office:word" xmlns:sl="http://schemas.microsoft.com/schemaLibrary/2003/core"	
xmlns:aml="http://schemas.micros	soft.com/aml/2001/core" xmlns:wx="http://schemas.microsoft.com/office/word/2003/auxHint"	
<pre>xmlns:o="urn:schemas-microsoft-</pre>	com:office:office" xmlns:dt="uuid:C2F41010-65B3-11d1-A29F-00AA00C14882"	
xmlns:wsp="http://schemas.micros	soft.com/office/word/2003/wordml/sp2″xmlns:st1=″urn:schemas-microsoft-com:office:smarttags″w:macrosPresent="no"	
→ w:embeddedObjPresent="no" w:ocxl	Present="no" xml:space="preserve">w:ignoreElements	
w:val="http://schemas.microsoft.	.com/office/word/2003/wordml/sp2"/> <o:smarttagtype <="" o:namespaceuri="urn:schemas-microsoft-com:office:smarttags" td=""><td></td></o:smarttagtype>	
<pre>&gt; o:name="State"/&gt;<o:smarttagtype< pre=""></o:smarttagtype<></pre>	o:namespaceuri="urn:schemas-microsoft-com:office:smarttags" o:name="City"/> <o:smarttagtype< td=""><td></td></o:smarttagtype<>	
o:namespaceuri="urn:schemas-mic	rosoft-com:office:smarttags" o:name="place"/> <o:documentproperties><o:title>症例報</o:title></o:documentproperties>	
告 <o:author>Norihiro</o:author>	/o:Author> <o:lastauthor>kamei</o:lastauthor> <o:revision>2</o:revision> <o:totaltime>1</o:totaltime> <o:created>2012-06</o:created>	
-01T05:03:00Z <o:las< td=""><td>tSaved&gt;2012-06-01T05:03:00Z<o:pages>1</o:pages><o:words>2497</o:words><o:characters>14236<td></td></o:characters></td></o:las<>	tSaved>2012-06-01T05:03:00Z <o:pages>1</o:pages> <o:words>2497</o:words> <o:characters>14236<td></td></o:characters>	
s> <o:company>Toshiba</o:company>	<pre>&gt;<o:lines>118</o:lines><o:paragraphs>33</o:paragraphs><o:characterswithspaces>16700</o:characterswithspaces><o:versi< pre=""></o:versi<></pre>	
on>11.0000	entProperties> <w:fonts><w:defaultfonts w:ascii="Century" w:cs="Times New&lt;/td&gt;&lt;td&gt;&lt;/td&gt;&lt;/tr&gt;&lt;tr&gt;&lt;td&gt;Roman" w:fareast="MS 明朝" w:h-ansi="Century"></w:defaultfonts><w:font w:name="Wingding&lt;/p&gt;&lt;/td&gt;&lt;td&gt;gs"><w:panose-1 w:val="050000000000000000000"></w:panose-1><w:charset w:val="02"></w:charset><w:family w:val="Auto"></w:family><w:pitch< td=""><td></td></w:pitch<></w:font></w:fonts>	
<pre>wival="variable"/&gt;<wisig pre="" wiusb-<=""></wisig></pre>	0="00000000" w:usb-1="10000000" w:usb-2="00000000" w:usb-3="00000000" w:csb-0="80000000"	
<pre>w:csb-1="00000000"/&gt;<w< pre=""></w<></pre>	:font w:name="MS 明朝"> <w:altname w:val="MS Mincho"></w:altname> <w:panose-1 w:val="02020609040205080304"></w:panose-1> <w:charset< td=""><td></td></w:charset<>	
<pre>w:val="80"/&gt;<w:family w:val="Ron&lt;/pre&gt;&lt;/td&gt;&lt;td&gt;man"></w:family><w:pitch w:val="fixed"></w:pitch><w:sig <="" td="" w:usb-0="A00002BF" w:usb-1="68C7FCFB" w:usb-2="00000010" w:usb-3="00000000"><td></td></w:sig></pre>		
wicsb-0="0002009F" wicsb-1="000	00000"/> <w:font_w:name="simsun"><w:altname_w:val="宋体"></w:altname_w:val="宋体"><w:panose-1< td=""><td></td></w:panose-1<></w:font_w:name="simsun">	
<pre>w:val="02010600030101010101"/&gt;</pre>	w:charset w:val="86"/> <w:family w:val="Auto"></w:family> <w:pitch w:val="variable"></w:pitch> <w:sig <="" td="" w:usb-0="00000003"><td>A NUMBER OF</td></w:sig>	A NUMBER OF
w:usb-1="080E0000" w:usb-2="0000"	00010" w:usb-3="00000000" w:csb-0="00040001" w:csb-1="00000000"/> <w:font w:name="Century"><w:panose-1< td=""><td>1121</td></w:panose-1<></w:font>	1121
w:val="02040604050505020304"/>	w:charset w:val="00"/> <w:family w:val="Roman"></w:family> <w:pitch w:val="variable"></w:pitch> <w:sig <="" td="" w:usb-0="00000287"><td></td></w:sig>	
<pre>w:usb-1="00000000" w:usb-2="0000</pre>	00000" w:usb-3="00000000" w:csb-0="0000009F" w:csb-1="00000000"/> <w:font w:name="@MS 明朝"><w:panose-1< td=""><td></td></w:panose-1<></w:font>	
<pre>w:val="02020609040205080304"/&gt;</pre>	w:charset w:val="80"/> <w:family w:val="Roman"></w:family> <w:pitch w:val="fixed"></w:pitch> <w:sig <="" th="" w:usb-0="A00002BF" w:usb-1="68C7FCFB"><th></th></w:sig>	
a w:usb-2="00000010" w:usb-3="0000	00000" w:csb-0="0002009F" w:csb-1="00000000"/> <w:font w:name="@SimSun"><w:panose-1< td=""><td></td></w:panose-1<></w:font>	

MS Open XML tags

### (2) Converting Microsoft Office Open XML to JATS XML

- Through XSLT, removing unnecessary tags.Perl program processing.
- We faced the difficulty of Asian languages
  A word connects to the next word without space.
  Computer cannot distinguish word separation.
  Even in given name and surname separation.

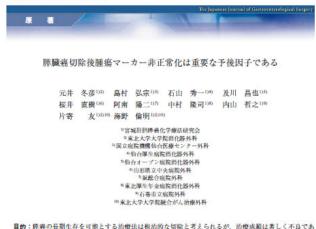
# (3) Validating XML

# Use the Oxygen XML editor Final JATS XML is obtained to be uploaded to J-STAGE



### PDF is still necessary

### 日本前化器外科学会辅助。2012,45(7):697-707



目的: 陸縮の長期生存を可能とする治療法は根治的な切除と考えられるが、治療成額は着しく不良であ る. 縮速残度 (residual tumor:以下,Rと時記)は切除例の予後因子だが,Rの切除後でも予発で例 の指標が必要である. 陸痛切除後に腫瘍マーカー (tumor marker:以下,TMと時記)が正常化しないこと があり、予後不良であると報告されている。今回アンケートで切除後 TM 正常化の有無と臨床病理学的因 子の関係を解析し、予後因子としての意義を明らかにした。対象:宮城肝胆膵縮化学療法研究会参加 21 施 設を対象に,2003 年 1 月から 2007 年 12 月までの 5 年間に切除された準痛 333 例中, 組織学的に通常型準 痛で,TM が測定された 294 例を対象とした。方法:年齢・性・病式・TM・補助療法などを問うアンケー トを集計し、術前 TM 非上昇、術後正常化・非正常化の 3 群に分け解析した。結果:CA19-9 が 67%、そ の他を含めると 80%の症例で上昇を認め、上昇例の約半数で切除後 TM 非正常化が認められた。術前非上 昇列、切除後正常化例の生存期間中央値が 364,245 か月に対し、非正常化何では 168 か月で有意に予後 不良であった。多変量解析では、病期と術後 TM が有意な予後因子として選別され、R0 切除サブ解析で も、術後 TM 非正常化では有意に予後不良であった。結語: 膵臓癌切除後腫塩マーカー非正常化は重要な 予後因子である。

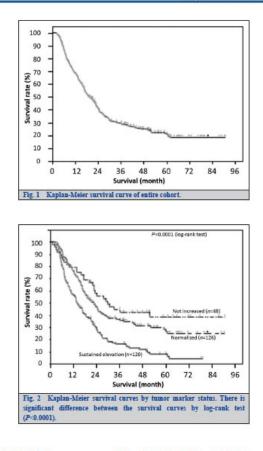
### はじめに

膵癌の長期生存を可能とする唯一の治療法は根治的な切除と考えられているが、切除例の大部分が再発し、その成績は差しく不良である<sup>112</sup>、切除例の子後因子として、進行度(stage)<sup>1121・</sup>腫瘍任<sup>1121・</sup>組織型(histological grade)<sup>1121・</sup>順衛任<sup>1121・</sup>組織型(histological grade)<sup>1121・</sup>順衛任<sup>1121・</sup>組織型(histological grade)<sup>1121・</sup>順衛援度(residual numor;以下,Rと略記)<sup>41</sup>などが報告されている。最も代表的な切除例の予後規定因子はRであり、R0切除例には希知。210年前期の近後にないる<sup>41</sup>ないたったった。 味する<sup>31</sup>、R0切除例は、R1、2切除例に比べ有意に生存期間が長いことが報告されている<sup>41</sup>ののの、一方 でR0切除後にも再発が生じることはまれではない<sup>1120</sup>、R1はあくまで手術野局所の評価であり、手術時に に存在すると考えられる不顕性の微小転移の存在を示唆する単活<sup>415</sup>から、R0切除後においても子後・再

(2012年2月22日受運) 別副構求先:元井 冬彦 〒960-8574 仙台市青寨区星陵町1-1 東北大学大学院医学承研究科外科病標学店化 器外科学分野

# For paper publishing.For readability.





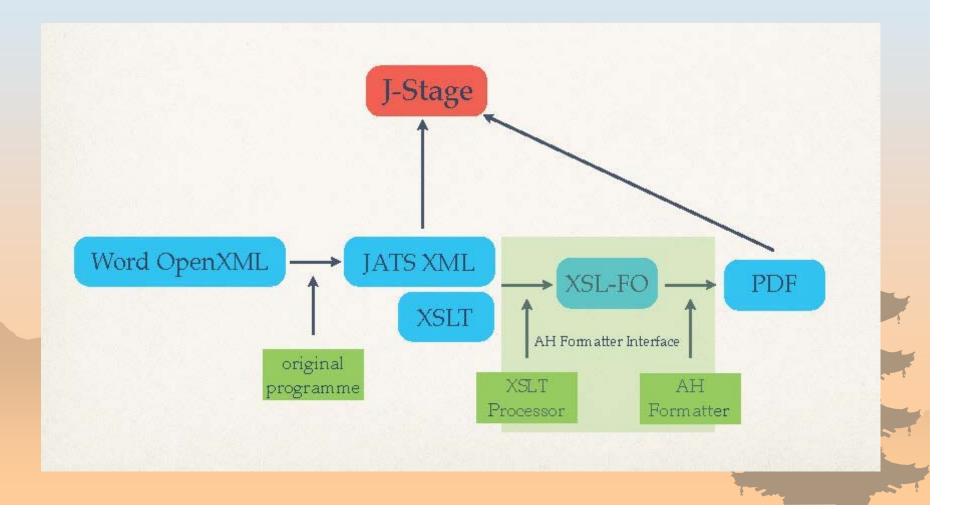
42.0, 31.7%, 非正常化群で 61.6, 18.4, 9.0%であり, 生存期間中央値は, 非上昇群で 1,092 日, 正常化群 で 736 日, 非正常化群で 505 日であった, 非正常化群で, 有意に生存期間が短く, 予後不良であった (Fig. 2, P < 0.0001, log-rank test).

### 4. 多変量解析による予後因子の抽出

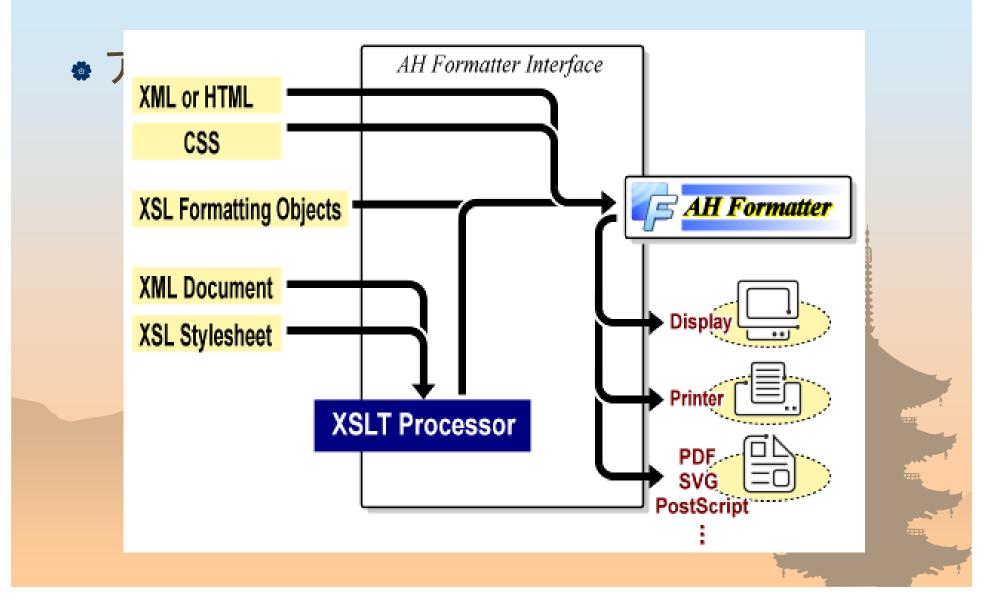
年齢・性・術前腫瘍マーカー・術式・進行度・組織型・病違残度・術後腫瘍マーカー・術後補助療法の 各因子で、Cox比例ハザードモデルを用い解析した.単変量解析では、術前腫瘍マーカー(CA19-9 上昇> 非上昇例)、術式(脾全摘>膵頭切除),進行度(stage 4 > stage 3 かつ stage 1-2 > stage 3),痛違残(R1-2 > R0),術後腫瘍マーカー(非正常化>非上昇例)が有意な予後因子として抽出された.それら単変量解 析で有意であった因子を用いて多変量解析を行うと、進行度、術後腫瘍マーカーが有意な予後規定因子と して選別された(Table 3).



# **Creating PDF using AH Formatter**



### Antenna House AH Formatter



### XSLT

### The XSLT converts a JATS file into XSL-FO which expresses page model format for PDF.



味するり、R0切除例は、R1、2切除例に比べ有意に生存期间が長いことが報告されているかものの、一方 でR0切除後にも再発が生じることはまれではない1000、Rはあくまで手術野局所の評価であり、手術時に 既に存在すると考えられる不顕性の微小転移の存在を示唆する報告かから。R0 切除後においても予後,再

(2012年2月22日受援) 別副線永先:元井 冬彦 〒 980-8574 仙台市青葉区星股町1-1 東北大学大学院医学系研究科外科病標学首化 器体科学分野



<?xml version="1.0" encoding="UTF-8"?> <!-- edited with XMLSpy y2012 sp1 (http://www.altova.com) by Kenichi Kusunoki (Nakanishi Printing Co., Ltd.) --> \txsl:stylesheet version="2.0" xmlns:xsl="http://www.w8.org/1999/XSL/Transform" xmlns:fo="http://www.w8.org/1999/XSL/Format" xmlns:xlink="http://www.w8.org/1999/XSL/Format" xmins:mml="http://www.w8.org/1998/Math/MathML" xmins:axf="http://www.antennahouse.com/names/XSL/Extensions" exclude-result-prefixes="xlink mml" xmlns:kk="http://www.nacos.com/2012/kusunoki"> Kxsl:import href="kk function.xsl"/> <!-- 『日本消化器外科学会雑誌』用スタイルシート --> <!-- by Antenna House, Inc., 2012-03-30 --> <!-- J-Stage3用スタイルシートをインポート --> <xsl:import href="jstage8-xslfo new.xsl"/> <!-- この雑誌のためだけの設定をここに。 --> <!-- 本文の行送り [jpub3-xslfo] --> <xsl:variable name="textleading">16.25pt</xsl:variable> <!--, ページの大きさと余白 -->, <xsl:variable name="page-width">210mm</xsl:variable> <xsl:variable name="page-height">297mm</xsl:variable> <xsl:variable name="page-margin-inside">30.387mm</xsl:variable> <xsl:variable name="page-margin-outside">30.387mm</xsl:variable> <xsl:variable name="page-margin-top">9mm</xsl:variable> For Japanese rendering <xsl:variable name="page-margin-bottom">15mm</xsl:variable> <xsl:variable name="page-body-margin-top">17mm</xsl:variable> AH Formatter extension <xsl:variable name="page-body-margin-bottom">12mm</xsl:variable> <xsl:variable name="page-column-count">1</xsl:variable> <xsl:variable name="page-column-gap">Omm</xsl:variable> <xsl:variable name="first-page-header-extent">23.573mm</xsl:variable> <xsl:variable name="trans-abstract-header-extent">16mm</xsl:variable> <xsl:variable name="page-header-extent">10mm</xsl:variable> Kxsl:variable\_name="page-footer-extent">4mmK/xsl:variable> <!-- ページヘッダー [jpub3-xslfo] --> <xsl:attribute-set name="page-header">  $\nabla$ <xsl:attribute name="font-family"><xsl:value-of select="\$textfont"/></xsl:attribute> <xsl:attribute name="font-size">7pt</xsl:attribute> <xsl:attribute name="line-height">7pt</xsl:attribute> (/xsl:attribute-set> <!-- ノンブル領域 [jpub3-xslfo] -->  $\nabla$ <xsl:attribute-set name="page-header-vol-title-cell"> <xsl:attribute name="width">auto</xsl:attribute> <xsl:attribute name="font-family">serif</xsl:attribute> <xsl:attribute name="font-weight">normal</xsl:attribute> <xsl:attribute name="font-size">?pt</xsl:attribute> <xsl:attribute name="start-indent">Opt</xsl:attribute> <xsl:attribute name="end-indent">Opt</xsl:attribute> </xsl:attribute-set>

## Challenges of Applying JATS to Japanese language texts

- But in Japan, exquisite type settings are requested.
- Automatic type setting by AH formatter may not be sufficient.

# Avoiding Word Breakup Some words, such as personal names shall not be broken-up between lines

(unacceptable)	(acceptable)	
この論文の主執筆者は中 西秀彦でした。	この論文の主執筆者は中西 秀彦でした。	

We use "Zero Width Joiner" code (‍)
e.g. 中‍西
「中」and「西」 are torn up by "&#x200D"
→「中西」cannot be searched

#### **Avoiding Line-Top Punctuations**

(unacceptable)

行頭・行末にあると体裁が悪い文 字を調整することを「禁則処理 」といいます。 (acceptable)

行頭・行末にあると体裁が悪い文 字を調整することを「禁則処理」 といいます。

• Punctuation marks shall not come at the top of a line  $\Rightarrow$  Also in English

「う」or「ツ」 (to mark a geminate consonant)
 does not come in a head of a line
 ⇒ Japanese rule

• AH Formatter can handle these rules

#### Positioning Figures/Tables

- Figures and tables should be positioned in the SAME page that the corresponding texts appear.
- This requires customized XSLT, sometimes for each figures and tables.
- This increases costs.

#### Positioning Figures/Tables

Every articles need these XSLTs

#### Using Formatter for STM articles

- There are no major problems
- The basic style of writing STM papers do not differ greatly between western countries and Japan.
- Word separators should be inserted in XML in advance

Possible if disregarding profitability

# Current Japanese XML journal

#### List of Japanese XML Journals

	1日本コンピュータ化学会	Journal of Computer Chemistry, Japan	混
	2日本育種学会	育種学研究	和
	3日本熱帯医学会	Tropical Medicine and Health	混
	4社団法人 日本産業衛生学会	産業衛生学雑誌	和
	5 特定非営利活動法人 日本歯周病学会	日本歯周病学会会誌	和
	6日本緩和医療学会	Palliative Care Research	混
	7日本応用糖質科学会	Journal of Applied Glycoscience	混
	8一般社団法人 日本鉄鋼協会	鉄と鋼	和
	9独立行政法人 海洋研究開発機構	JAMSTEC Report of Research and Development (JAMSTEC-R)	混
1	0日本官能評価学会	日本官能評価学会誌	混
1	1 一般社団法人 日本消化器外科学会	日本消化器外科学会雑誌	混
1	2公益社団法人 日本看護科学学会	日本看護科学会誌	和
1	3日本行動医学会	行動医学研究	混
1	4日本社会心理学会	社会心理学研究	混
1	5日本公衆衛生看護学会	日本公衆衛生看護学会誌	和
1	6科学技術振興機構	情報管理	和

混:English Japanese mixed up 和:Pure Japanese April 2016 JST provided

#### Few Japanese XML Journals

- The total number of pure Japanese journals in J-STAGE is 568
- The number of pure Japanese XML Journal is only 7
  - After 4 years have passed

## The difficulties of creating Japanese XML

- Labor and time are necessary
- Which require additional costs
- It is hard for publishers to find more merits than PDF journal

The most difficult problem No separating spaces
Typical in East Asian languages
No separating spaces between words

#### Inserting word separators.

• we insert separators manually.

- surname, "中", given name, "吉昭", are attached as "中吉昭" in an article

- It is separated as "中@吉昭"

 Possible alternatives are "中@吉昭", and "中 吉@昭", but only human can eliminate them

• There is no algorithm to determine it correctly.

#### Tools necessary for us

XML tool of the East Asia cultural sphere
The inputting tool is necessary at first

Not MS WORD



- We need input tools for Japanese XML
- A common tools for the East Asia cultural sphere Japan, China and Korea is needed!

# Future

What is to be done next
-Vertical writing
-Emphasis or "Kenten"
-Warichu

#### Vertical writing

(あいうえお) かきくけこ

Traditionally, Japanese
 (and Chinese and
 Korean) writes from top
 to bottom

#### Vertical Writing

Vertical Writing
 causes some
 interesting problems,
 orientation of Arabic
 numerals and Latin
 alphabets

New element for direction is necessary. as <writing-direction="vertical">

#### Emphasis

- あいうえお
  - かきくける

- Emphasis or "Kenten"
- It is like bold faces and italics in English
- We use <styled-content>for these expressions
- We need a generic tag, like as <emphasis>

#### Warichu

かきくけこ(これは見) かきくけこ 、本です。

 Vertical writing texts sometimes contain notes called "Warichu".

 Warichu uses 2 lines within a parent line.

#### Warichu

Historical document example

#### Suggestion

Additional tags for
-Vertical writing
-Emphasis or "Kenten"
-Warichu

# Conclusion

- JATS opened a new horizon in processing Japanese-language articles
  - No major difficulties
  - UTF-8, encoding for XML, also enables to express most Japanese characters correctly

#### Conclusion

 Still there are remaining issues in processing non-Latin languages such as Japanese.

#### Challenges

- Word separators have to be inserted manually
- Line break issues
- Positioning figures and tables correctly
- Some requests to JATS
   for applying Asian languages

# **Only English is not globalization**

#