

NewsMLを活用した ニュース検索Webサービスの構築

2002年6月13日

XMLコンソーシアム
応用技術部会 WebサービスWG

アジェンダ

- WebサービスWGの活動状況
- NewsMLを活用した
ニュース検索Webサービスの構築
- Demonstration
- 所感(接続実験参加者)
- 今後の課題

応用技術部会 WebサービスWG

■目的

- XML適用システムの開発を通し、XML技術の向上および普及に努める。
 - プロトタイプ開発を通じた技術習得
 - XML利用上の課題の解決技術確立
 - XML製品の利用技術の習得

■活動内容

- XML基盤技術の評価を目的とした実証実験、プロトタイプシステム開発
- 実用(アプリケーション)システムへの適用性評価を目的としたプロトタイプシステム開発
- ベンダー各社が提供するXML関連プロダクトの評価


WebサービスWGでは
Webサービスを利用したプロトタイプ開発

1年間の活動状況(1)

活動内容

第1回 XMLコンソーシアムDay(11月22日)

第2回 XMLコンソーシアムDay(2月6日)



ナレッジWebサービスの
実装

四則演算Webサービスの
実装

本格的なWebサービスを
実装

WebサービスWG
発足

Webサービスを
体感したい

2001/06

2002/01

2002/06

活動時期

ナレッジWebサービス実装の評価

■評価

- Webサービスの実装作業自体は有意義
 - アプリケーションサーバの使い方
 - インターフェースの定義/実装の習得
 - 本格的なWebサービスを実装した達成感
- 実装されたナレッジWebサービスに面白みに欠けた
 - 提供サービス(コンテンツ)が少なかった
 - ビジネス要素が少なく、リアリティに欠ける

■ステップアップに向けた方針

- 実ビジネス要素を加味した、リアルなWebサービスの実装
- 提供サービスの充実化(異種サービスの実装)
- 実装方法の更なる拡大(アプリケーションサーバ,開発言語)

期待


- 充実したサービスの実装
- 実際に使われているコンテンツ

NewsMLを使ったWebサービスの実装

NewsMLを活用したニュース検索Webサービス

■提供するWebサービス

- 複数の(仮想)新聞社/通信社/気象情報提供会社が提供する情報/コンテンツを1箇所のポータルサイトから検索
- 検索サービス利用者は、情報の所在(URL)を意識せずに単一のインタフェースで情報を取得することができる。
- 新聞記事は、NewsML形式で取り出せるだけでなく、スタイルシートにより、画像データを含んだHTML形式でWebブラウザから見る事ができる。



記事検索方法

検索キーワードの指定

検索キーワード

- 分類
- 記事タイトル
- 記事本文
- 日時
- 画像データの有無

キーワードに該当する記事の一覧表示

- (仮想)新聞社/通信社からニュースコンテンツをWebサービスを使って集約


表示する記事の選択

- 選択された記事を(仮想)新聞社/通信社から取り出し
- 記事当日の気象情報を気象情報提供会社から取り出し

記事の表示

- NewsMLと気象情報をスタイルシートを使ってHTMLに変換

処理シーケンス



サービス/メッセージ一覧

トピックセット
Webサービス

新聞記事検索
Webサービス

気象情報検索
Webサービス

| サービス(service) | 操作(operation) | メッセージ(message) | パラメタ(part) | |
|--------------------|-----------------------|-------------------------|------------------|------------------|
| | | | 型(type) | 名前(name) |
| TopicSetService | getSubjectCodes | getSubjectCodes | - | - |
| | | getSubjectCodesResponse | xsd:string | return |
| NewsMLService | search | search | xsd:string | subjectCode |
| | | | xsd:string | titleKeyword |
| | | | xsd:string | bodyKeyword |
| | | | xsd:boolean | hasImage |
| | | | xsd:string | dateFrom |
| | | | xsd:string | dateTo |
| | searchResponse | xsd:string | return | |
| | getArticle | getArticle | xsd:string | publicIdentifier |
| getArticleResponse | | xsd:string | return | |
| getStylesheet | getStylesheet | xsd:string | publicIdentifier | |
| | getStylesheetResponse | xsd:string | return | |
| WeatherService | getWeather | getWeather | xsd:string | date |
| | | getWeatherResponse | xsd:string | return |

TopicSetサービス: TopicSetService

NewsMLで使用されるTopicSetに関するサービスを提供

■SubjectCode: 記事分類(政治、経済、スポーツ、芸能など)

- 大分類(TopicType@FormalName="Subject", 17個)
 - ◆FormaName要素の内容が"15000000"は"スポーツ"
- 中分類(TopicType@FormalName="SubjectMatter", 286個)
 - ◆FormaName要素の内容が""15054000"は"サッカー"
- 小分類(TopicType@FormalName="SubjectDetail", 616個)
 - ◆FormaName要素の内容が、"15073018"は"ワールドカップ"

➡コードによる分類によって、言語に依存しない、分類検索が可能となる

■Status: 記事の状態

- Usable : 公開可能
- Embargoed : 公開待機
- Withheld : 公開未定
- Canceled : 公開取消

■Country: 国

- JP: 日本
- KP: 韓国

■:



✓NewsMLを分類で検索するためには、SubjectCodeを使用する必要がある。

➡TopicSetに関するサービスが必要になる。

✓NewsMLの世界で共通なため、新聞社/通信社が提供する検索サービスとは、別サービス化

記事分類一覧の取得:getSubjectCodes

新聞記事の分類名と、分類名に対応するSubjectCodeの一覧を提供する操作

アグリケーション
サービス

トピックセット
Webサービス

getSubjectCodes()

getSubjectCodesResponse(xsd:string return)

getSubjectCodesResponseで返すデータは、日本新聞協会NewsMLで公開されている用語セット(TopicSet)のSubjectCode(topicset.iptc-subjectcode-ja)から、Subject(大分類)のコードを返す。DTDは、NewsMLv1.0.dtdを利用(下記のDTD参照)。

*参考: Subject(大分類):17個, SubjectMatter(中分類):286個, SubjectDetail(小分類):616個

```
<!ELEMENT NewsML (Catalog?, TopicSet*, (NewsEnvelope, NewsItem+))>
<!ELEMENT NewsItem (Comment*, Catalog?, Identification, NewsManagement, (NewsComponent | Update+ | TopicSet)?)>
<!ELEMENT TopicSet (Comment*, Catalog?, TopicSetRef*, Topic*)>
<!ATTLIST TopicSet
  Duid CDATA #IMPLIED
  FormalName CDATA #IMPLIED>
<!ELEMENT Topic (Comment*, Catalog?, TopicType+, FormalName*, Description*, Property*)>
<!ATTLIST Topic
  Duid CDATA #IMPLIED
  Details CDATA #IMPLIED >
```

getSubjectCodesResponseの戻り値 (抜粋)

```
<NewsML>
  <NewsItem>
    <TopicSet Duid="IptcSubjectCodes.subject" Scheme="IptcTopicType" FormalName="SubjectCode">
      <Topic Duid="sr01000000">
        <TopicType Scheme="IptcTopicType" FormalName="Subject"/>
        <FormalName Scheme="IptcSubjectCodes">01000000</FormalName>
        <Description xml:lang="en" Variant="Name">Arts, Culture & Entertainment</Description>
        <Description xml:lang="en" Variant="Explanation">Matters pertaining to the advancement and refinement of the human mind, of interests, skills, tastes and emotions</Description>
        <Description xml:lang="ja" Variant="Name">芸術、文化、娯楽</Description>
        <Description xml:lang="ja" Variant="Explanation">人間の精神や興味、技能、嗜好、感情の進歩や洗練に関する事柄。
      </Description>
    </Topic>
    <Topic Duid="sr13000000">
      <TopicType Scheme="IptcTopicType" FormalName="Subject"/>
      <FormalName Scheme="IptcSubjectCodes">13000000</FormalName>
      <Description xml:lang="en" Variant="Name">Science & Technology</Description>
      <Description xml:lang="en" Variant="Explanation">All aspects pertaining to human understanding of nature and the physical world and the development and application of this knowledge</Description>
      <Description xml:lang="ja" Variant="Name">科学、テクノロジー</Description>
      <Description xml:lang="ja" Variant="Explanation">人の自然や物理的世界に対する理解のあらゆる面、およびこの知識の発展や
    応用</Description>
    </Topic>
    <Topic Duid="sr15000000">
      <TopicType Scheme="IptcTopicType" FormalName="Subject"/>
      <FormalName Scheme="IptcSubjectCodes">15000000</FormalName>
      <Description xml:lang="en" Variant="Name">Sport</Description>
      <Description xml:lang="en" Variant="Explanation">Competitive exercise involving physical effort. Organisations and bodies involved in these activities.</Description>
      <Description xml:lang="ja" Variant="Name">スポーツ</Description>
      <Description xml:lang="ja" Variant="Explanation">フィジカル努力を含む競争力があるエクササイズ。組織、および団体は、これらの活動で含みました。</Description>
    </Topic>
  </TopicSet>
</NewsItem>
</NewsML>
```

NewsML検索時に使用

検索画面の選択候補に使用

記事検索サービス: NewsMLService

NewsMLの検索とその表示に関するサービスを提供

■ **search**: 検索条件に従って記事の一覧情報を検索するサービス

➢ 検索キーワード

- 分類 : 指定されたSubjectCodeで絞込み
- タイトル : 文字列の部分一致
- 本文 : 文字列の部分一致
- 画像データの有無 : 画像データが存在するものだけを対象にする場合
- 記事の年月日 : 開始年月日～終了年月日の範囲指定

■ **getArticle**: 指定されたPublicIdentifierのNewsMLを取り出すサービス

■ **getStylesheet**: PublicIdentifierで指定されたNewsMLをHTML形式で表示するために必要なスタイルシート(XSLT)を取得するサービス

PublicIdentifier: NewsML個々に付与された世界でユニークなID

記事一覧検索: search

利用者から指定された検索条件に従って、該当する記事を検索する操作

アプリケーション
サービス

新聞記事検索
Webサービス

```
search(xsd:string  subjectCode,  
       xsd:string  titleKeyword,  
       xsd:string  bodyKeyword,  
       xsd:boolean hasImage,  
       xsd:string  dateFrom,  
       xsd:string  dateTo)
```

```
searchResponse(xsd:string return)
```

記事一覧検索要求メッセージ: search

| パラメタ名 | パラメタ型 | パラメタ説明 | 検索対象(NewsMLの要素) |
|--------------|-------------|---|--|
| subjectCode | xsd:string | subjectCodeで検索する | /NewsML/NewsItem/NewsComponent/DescriptiveMetadata/SubjectCode/Subject/@FormalName 文字列 完全一致 |
| titleKeyword | xsd:string | タイトルで検索する | /NewsML//NewsComponent/NewsLines/HeadLine 文字列 部分一致のみ |
| bodyKeyword | xsd:string | 本文で検索する | //DataContent の中 文字列 部分一致のみ |
| hasImage | xsd:boolean | イメージがあるものだけを検索する場合にtrue、イメージが無いものも検索対象にする場合はfalse | //ContentItem/MediaType を見て画像データが存在するか |
| dateFrom | xsd:string | 記事の作成日時で検索する | /NewsML//NewsItem/NewsManagement/ThisRevisionCreated •検索対象は年月日のみ •開始年月日, 終了年月日は「その日を含んで」 |
| dateTo | xsd:string | 記事の作成日時で検索する | |

example

記事一覧検索応答メッセージ: searchResponse

| パラメタ名 | パラメタ型 | 内容 |
|-------|------------|---------------------------------|
| rerun | xsd:string | 指定された検索条件に合致した記事の一覧を下記のデータ構造で返す |

データ構造

```
<!ELEMENT articleInfo      (article*)>
<!ELEMENT article          (publicIdentifier, title, date, copyrightHolder, hasImage)>
<!ELEMENT publicIdentifier  (#PCDATA)>
<!ELEMENT title            (#PCDATA)>
<!ELEMENT date             (#PCDATA)>
<!ELEMENT copyrightHolder  (#PCDATA)>
<!ELEMENT hasImage         (#PCDATA)>
```

| 要素名 | 説明 | 内容(NewsMLの要素) |
|------------------|---|---|
| publicIdentifier | NewsMLの一意のID | /NewsML/NewsItem/Identification/NewsIdentifier/PublicIdentifier |
| title | 記事のタイトル | /NewsML//NewsComponent/NewsLines/HeadLine |
| date | 記事の作成日 | /NewsML/NewsItem/NewsManagement/ThisRevisionCreated |
| copyrightHolder | 著作権保持者 | //NewsComponent/RightsMetadata/Copyright/CopyrightHolder |
| hasImage | 画像データの有無 •true: 画像データが有る場合 •false: 画像データが無い場合 | //ContentItem/MediaType を見て画像データが存在するか |

記事取り出し: getArticle

指定されたPublicIdentifierのNewsMLを取り出す操作

アプリケーション
サービス

新聞記事検索
Webサービス

getArticle(xsd:string publicIdentifier)

getArtcileResponse(xsd:string return)

記事取り出し要求メッセージ: getArticle

| パラメタ名 | パラメタ型 | パラメタ説明 |
|------------------|------------|----------------------------------|
| publicIdentifier | xsd:string | 利用者が記事一覧で選択した記事のpublicIdentifier |

記事取り出し応答メッセージ: getArticleResponse

| パラメタ名 | パラメタ型 | 内容 | NewsMLの要素 |
|-------|------------|------------------------------|---|
| rerun | xsd:string | 指定されたpublicIdentifierのNewsML | /NewsML/NewsItem/Identification/NewsIdentifier /PublicIdentifier |

スタイルシート取り出し: stylesheet

記事(NewsML)の表示方法(スタイルシート)を取り出す操作

アプリケーション
サービス

新聞記事検索
Webサービス

stylesheet(xsd:string publicIdentifier)

stylesheetResponse(xsd:string return)

- NewsMLの記事本文(//NewsComponent/ContentItem/DataContent)のスキーマ構造は、NewsML毎に異なる。
- NewsComponentは、入れ子構造を持つことができる
- NewsMLをどのように表示するかは、著作権者の意志



- 記事(NewsML)を表示するためのスタイルシートを取り出すための手段が必要
- 今回のスタイルシートは、NewsMLの作成社が提供

スタイルシート取り出し要求メッセージ: getStylesheet

| パラメタ名 | パラメタ型 | パラメタ説明 |
|------------------|------------|----------------------------------|
| publicIdentifier | xsd:string | 利用者が記事一覧で選択した記事のpublicIdentifier |

スタイルシート取り出し応答メッセージ: getStylesheetResponse

| パラメタ名 | パラメタ型 | 内容 |
|-------|------------|---|
| rerun | xsd:string | 指定されたpublicIdentifierのNewsMLを表示(HTML)するためのスタイルシートのURL |

- 指定されたPublicIdentifierのNewsMLを検索
- NewsMLの中の/NewsML/NewsEnvelope/NewsService/@FormalNameの値に従って、対応するNewsML用のスタイルシートのURLを返す

気象情報検索サービス: WeaaherService

気象情報に関するサービスを提供

アプリケーション
サービス

気象情報検索
Webサービス

getWeather(xsd:string date)

getWeatherResponse(xsd:string return)

気象情報取り出し要求メッセージ: getWeather

| パラメタ名 | パラメタ型 | パラメタ説明 |
|-------|------------|----------------------------|
| date | xsd:string | 気象情報を取り出す日付をyyyymmddの形式で指定 |

example

気象情報取り出し応答メッセージ: getWeatherResponse

| パラメタ名 | パラメタ型 | 内容 |
|-------|------------|---|
| rerun | xsd:string | 指定された日付の気象情報を下記のデータ構造で返す。 ただし、観測点は東京のみ |

データ構造

```
<!ELEMENT weatherInfo (date,weather,min,max)>  
<!ELEMENT date (#PCDATA)>  
<!ELEMENT weather (#PCDATA)>  
<!ELEMENT min (#PCDATA)>  
<!ELEMENT max (#PCDATA)>
```

| 要素名 | 説明 |
|---------|---|
| date | 日付 |
| weather | 天気 晴れ、曇り、雨、 晴れのち曇り、曇りのち晴れ、晴れのち雨、雨のち晴れ、雨のち曇り、曇りのち雨、 晴れ一時曇り、曇り一時晴れ、晴れ一時雨、雨一時晴れ、雨一時曇り、曇り一時雨 |
| min | 最低気温() |
| max | 最高気温() |

example

コンテンツについて

今回の実証実験を行うにあたって、下記のコンテンツを利用


- 気象サービス様 気象情報
- 共同通信社様 NewsML、及びスタイルシート
- 毎日新聞社様 NewsML、及びスタイルシート
- 読売新聞社様 NewsML、電光用NewsML、及びスタイルシート
(50音順)
- NewsML WG JavaコンソーシアムNewsML、及びスタイルシート

共同通信社様のメディア用
ニュース素材配信
サービスNEWSPACKの
コンテンツ(SOAP配信可能)

- ◆ コンテンツの利用に際し、ご協力いただきました各社様に厚く御礼申し上げます。
- ◆ NewsMLに関して技術的指導を賜りました応用技術部会
 - 日本アイ・ビー・エム(株) 様
 - 日本電気(株) 様
 - 日本ユニシス(株) 様
 - (株)読売新聞社 様
 - その他NewsML-WGメンバー 様

ご協力ありがとうございました。

接続実験参加企業/アプリケーションサーバ

| サービス | | サーバ |
|-----------------------------|--|---|
| アグリゲーション サーバ |  RICOH SYSTEM KAIHATSU COMPANY, LTD. リコーシステム開発株式会社 | BEA WebLogic Server 6.1J |
| トピックセット Webサービス |  日進ソフトウェア(株) | Apache AXIS Beta1 |
| 共同通信社様 新聞記事検索 Webサービス |  日進ソフトウェア(株) | Microsoft Visual Studio .NET |
| |  (株)日立製作所 | HITACHI Cosminexus Version 5 |
| 読売新聞社様 新聞記事検索 Webサービス |  富士通(株) | FUJITSU INTERSTAGE V4.0L20 |
| |  (株)東芝 | IBM WebSphere Application Server4.0 |
| |  日本オラクル(株) | Oracle9i Application Server Release2 |
| |  野村総合研究所 | |
| |  日本電気(株) | NEC ActiveGlobe WebOTX Ver4.2 |
| |  PFUアクティブラボ(株) | |

接続実験のシステム構成



トピックセット Webサービス
•Apache AXIS Beta1
•日進ソフトウェア



共同通信社様新聞記事検索 Webサービス
•Visual Studio .NET
•日進ソフトウェア



毎日新聞社様新聞記事検索 Webサービス
•Cosminexus Version 5
•日立製作所



読売新聞社様新聞記事検索 Webサービス
•INTERSTAGE V4.0L20
•富士通



読売新聞社様電光記事検索 Webサービス
•WebSphere Application Server4.0
•東芝



読売新聞社様電光記事検索 Webサービス
•Oracle9i Application Server Release2
•日本オラクル




Javaコンソーシアム記事検索 Webサービス
•Orbix E2A XMLBus Edition 5.1
•野村総合研究所



気象情報検索 Webサービス
•ActiveGlobe WebOTX
•日本電気

開発/接続実験スケジュール



実装方法に依存しないWebサービス

■アプリケーションサーバ

- 9種類のアプリケーションサーバを利用

■開発言語

- Java
- C#

■XMLデータの格納方法

- RDB(カラムマッピング、バイナリ格納)
- XML専用データベース
- フラットファイル

■XMLデータの検索方法

- XPath
- 文書管理システム
- 全文検索エンジン
- DOMで独自処理

Demonstration

by リコーシステム開発)八尋

接続実験の様子



2002年6月4日 日進ソフトウェア様社内にて

所感

- リコーシステム開発) 八尋
 - ➔アグリゲーションサービス
- 日進ソフトウェア) 定村
 - ➔TopicSet Webサービス
- 日進ソフトウェア) 荒本
 - ➔共同通信社様 新聞記事検索Webサービス
- 富士通) 山本
 - ➔読売新聞社様 新聞記事検索Webサービス
- 日立製作所) 葛坂
 - ➔毎日新聞社様 新聞記事検索Webサービス
- 東芝) 山田
 - ➔読売新聞社様 電光記事検索Webサービス
- 日本オラクル) 鈴木
 - ➔読売新聞社様 電光記事検索Webサービス
- 野村総合研究所) 坂田
 - ➔Javaコンソーシアム記事検索サービス
- NEC) 高橋
 - ➔気象情報検索Webサービス
- PFUアクティブラボ) 松山
 - ➔取り纏め

(敬称略)

1年間の活動状況(2)

活動内容

第1回 XMLコンソーシアムDay(11月22日)

第2回 XMLコンソーシアムDay(2月6日)

ニュー
XML
Week



NewsMLを活用した
ニュース検索Webサービスの
実装

Next Step



ナレッジWebサービスの
実装



リアルなサービスを想定した
Webサービスの実装



四則演算Webサービスの
実装



本格的なWebサービス
の実装



WebサービスWG
発足



Webサービスを
体感したい

2001/06

2002/01

2002/06

活動時期

活動評価

もう一度
振り返って

目的

- プロトタイプ開発を通じた技術習得 
 - ➔ 算術演算Webサービス
 - Webサービスを体験
 - ➔ ナレッジWebサービス
 - 複数のWebサービスを連携
 - ➔ ニュース検索Webサービス
 - 実世界で使われているコンテンツを利用
- XML利用上の課題の解決技術確立 
 - ➔ Webサービスを使ったシステム開発手順の確立
 - ユースケース
 - 外部インターフェース(WSDLなど)
 - サービス実装
 - 接続
- XML製品の利用技術の習得 
 - ➔ 計11種類のアプリケーションサーバを使用
 - ➔ XMLストレージ
 - ➔ RDB(カラムマッピング、バイナリ化格納)
 - ➔ XMLデータベース



今後の課題

■技術的には

- アグリゲーション型(Pull型)以外のWebサービス
 - 配信型(Push型)
 - 非同期型
 - コンテンツからサービスへ
- トランザクション処理
 - コミットとロールバック(課金処理など)
 - 動的フロー制御(動的なWebサービスの利用)
- UDDI
 - ローカル(企業内、業界内、地域)
 - グローバル
- サービスレベル
 - 性能:スピード
 - 品質:信頼性
 - セキュリティ(暗号化、外部攻撃)

■方法論として

- XMLコンソーシアムが提供するWebサービス
- 他WG、部会、Webサービス推進委員会との連携
 - ✓NewsML WGとの連携が成功!

Webサービスの普及の一助となれば幸い

ご清聴ありがとうございました。

END