

文字コード独立の多言語テキスト editor の実装

5R-10

張暘 梅村恭司

豊橋技術科学大学 情報工学系

1. はじめに

文字コードと符号化方式が多種多様にあり、これらを統一的に処理するためには、OS を国際化すべきであり、Unicode の採用はその手段のひとつであると考えられる。しかしながら、それは様々な要因で、まだ広い範囲でサポートされていない。また、たとえ Unicode を使っても、異なる文字コードを同時に表示させることができないという問題がある。

本研究では、文字コードに依存したテキスト文字を文字コードに依存しない GIF ファイルに対応づけることで、文字コードに独立した HTML ファイルに変換するツールを作成した。この HTML ファイルを元のテキストファイルと同じインターフェースで表示しながら編集できる editor を作成することで、事実上の多言語テキスト editor を実現した。また、文字コードセットを拡充でき、OS ではサポートされていない言語にも対応することができる。

2. システムの概要

システムの開発では、Java 言語を用いる。Linux と Windows 95 および Windows 98 では、システムが正しく動作することが確認できた。システムが対応している文字コードセットは日本語（JIS、SJIS、EUC）と中国語（GB、HZ「簡体字」と BIG5「繁体字」）と英語（ASCII）である。このシステムは BdxToGif クラスと TxtToHtml クラスの二つツールおよび多言語テキスト editor から構成される。BdxToGif は Linux 上の各コード体系の BDF ファイル（テキストファイル）から各コード体系の GIF library を作るツールである。TxtToHtml は各コード体系のテキストファイルを HTML ファイルに変換するツールである。

3. 実現方法

多言語テキスト editor を使うには、まず、BdxToGif を使って、各コード体系の GIF library を作っておく必要がある。新たなニーズによって、新しいコード体系が必要になれば、このツールを使って、GIF library を追加すれば良い。TxtToHtml を使うと、変換対象になる各テキストファイルのコード体系に対応する変換クラスが呼び出されて、HTML ファイルが作成される。これは、文字コード体系に依存するテキストファイルの文字を文字コード体系に依存しない GIF 形式の画像ファイルに対応させたものである。多言語テキスト editor をマルチウインドウで実現し、いくつかの必要な HTML ファイルを多言語テキスト editor の各ウインドウにロードして、多言語テキスト editor の編集機能を利用し

Implementation of multiple languages' text editor independent of character encoding

Yang Zhang and Kyoji Umemura

Department of Information and Computer Sciences, Toyohashi University of Technology

て、元のコード体系に依存しない多言語 HTML ファイルが作成できる。(多言語テキスト editor で表示されるのは、元のテキストと同じだが、実際に編集されるのは HTML ファイルである。) また、多言語テキスト editor は HTML ファイル以外に X-bitmap 形式の画像ファイルでも出力することができる。

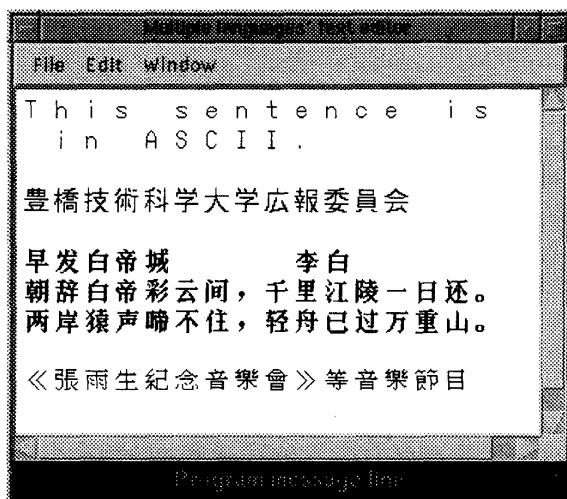


図 1

```

Buffers Files Tools Edit Search Help


<br>


<br>


<br>
<br>



L:-----Emacs: demo1.html (Fund)

```

図 2

実行例として、多言語テキスト editor の編集機能を利用して作られた多言語 HTML ファイルを表示した例を図 1 に示す。この HTML ファイルは英語、日本語、中国語 GB (大陸、シンガポールなどで使われた「簡体字」)、中国語 BIG5 (台湾、香港などで使われた「繁体字」) の文字を含んでいる。図 2 はこの HTML ファイルのコードの一部分である。

4. システムの性能

本システムは GIF library を使うので、ハードディスクに多くのスペースが要求される。(ひとつ GIF ファイルのサイズは 100 バイト以内である。) 作られた HTML ファイルのサイズも大きいである。表示するときに、ハッシュテーブルを使って、必要な GIF ファイルだけをメモリに読み込むので (ハッシュテーブルに登録した GIF ファイルをロードしない)、表示の実行時間はテキスト中の文字の種類の数に依存する。また、システムの性能を向上させるには、多量のメモリが必要である。実験では、Java インタプリターのヒープメモリを多く指定すれば、実行時間は半分以下になった。市場の主流マシンでは、十分実用に耐えるものである。

5. おわりに

本研究では、我々は文字コード独立の多言語テキスト editor を実装した。これにより、多言語テキストを統一的に表現することが可能になった。現在、本システムは日本語 (JIS, SJIS, EUC) と中国語 (GB, BIG5, HZ) と英語 (ASCII) に対応しており、対応するコードがない文字も処理できる。

参考文献

- 「1」Ken Lunde：日本語情報処理，ソフトバンク株式会社（1995）
- 「2」有賀 妙子・竹岡 尚三：Java1.1 プログラミング，ソフトバンク株式会社（1997）