

Jcode を使おう (実用本位の Jcode 紹介)

Kiyoka Nishiyama

(http://www.netfort.gr.jp/~kiyoka/jcode_intro/index.html)

\$Date: 2000/11/29 15:40:18 \$

目次

1	はじめに	1
1.1	目的	1
1.2	アプローチ (5W1H で見る)	1
2	Jcode 概説	1
2.1	what:何か	1
2.2	why:なぜ Jcode か?	2
2.3	when:どんな場面で使えるのか	2
2.4	where:どんな環境で使えるのか	2
2.5	who:誰が使うのか (それは、もちろんあなたです。)	2
2.6	how:どうやって使うのか	3
3	漢字コードについての基礎 (深い話題は除く)	3
3.1	perl とマルチバイト処理の関係	3
4	getcode メソッドと convert メソッド	3
4.1	jcode.pl レガシーインターフェースとオブジェクト指向インターフェース	3
4.2	getcode メソッド - エンコードを調べる	4
4.3	convert メソッド - 任意のエンコードに変換する	4
5	サンプルコードによるデモ	4
5.1	perl5.6 のテスト	4
5.2	文字コード判別 (getcode メソッド使用)	4
5.3	nkf もどき (convert メソッド使用)	5

6	付録:その他のリソース	5
6.1	perl がインストールされている環境で見れる資料	5
6.2	インターネット上のリソース	5
6.3	書籍	6

1 はじめに

1.1 目的

- Jcode を即使えるようになる。(Perl の基礎知識は必要)

1.2 アプローチ (5W1H で見てみる)

1. what: Jcode とは何か
2. why: なぜ Jcode か？
3. when: どんな場面で使えるのか
4. where: どんな環境で使えるのか
5. who: だれが使うのか？(それは、もちろんあなたです。)
6. how: どうやって使うのか

2 Jcode 概説

2.1 what: 何か

1. 日本語文字コード用汎用モジュールである
 - Perl Module 化されている (.pl 版もあるが、perl5 が普及している今日では、pm 版を使うべき)
2. 基本的な機能は、文字コード判別、変換
 - 本資料ではこの機能のみ紹介
3. サポートする文字コード
 - ascii, binary, euc, sjis, jis, ucs2, utf8
4. 開発者・開発チーム
 - オリジナルである jcode.pl は歌代和正氏が開発された。(現在もメンテナンスが行なわれている)

補足

この講演資料は、Jcode の全ての事柄を網羅しているわけではありません。現時点で Jcode を使い始める上で知っておくべき情報をまとめたものです。

- Jcode.pm は jcode.pl のコードを元に、RingServer 上の OpenLab で開発されている

2.2 why:なぜ Jcode か？

1. デバッグ済みコードを使おう

- 車輪の再発明を避けよう
- 要は、楽をしよう

2. なぜ Jcode が必要なのか？

- perl はいろんな日本語文字コードを認識してくれない
 - perl5.6 を使えば utf-8 の文字コードは認識してくれるがそれ以外の文字コードは認識してくれない
 - perl5.6 でも未だ漢字コード変換はサポートされていない
- Web 上の HTML ファイルは、sjis,jis,euc 等バラバラ。
 - HTML ファイルを処理するのに、あらゆるコードを処理するプログラムを書くの？->Jcode を使おう

2.3 when:どんな場面で使えるのか

1. HTML ファイルの文字コード変換・チェック (ヘッダの文字コード指定と、ファイルの文字コードがマッチしているかどうかなど)
2. perl プログラムから送信する Mail の文字コード変換
3. CGI へのフォーム入力データの文字コード変換/半角・全角変換 (詳しい方、補足お願いします。)

2.4 where:どんな環境で使えるのか

- jcode.pl なら perl4 以上で使用できる
- Jcode.pm なら perl5 以上で使用できる
 - 但し、perl スクリプト内で正規表現などを使って日本語を処理したい場合は、jperl4,jperl5 か、perl5.6 以上を使う必要があります。

2.5 who:誰が使うのか (それは、もちろんあなたです。)

- Perl で日本語を使う必要のある人は Jcode を使いましょう

2.6 how:どうやって使うのか

- 次章から次のような手順で見っていきます
 - 漢字コードについての基礎
 - getcode メソッドと convert メソッド
 - 簡単なデモの紹介 (perl5.6 のテスト・コード判別・nkf もどき)

3 漢字コードについての基礎 (深い話題は除く)

3.1 perlとマルチバイト 処理の関係

- perl でマルチバイトを操作したい場合は、jperl か、perl5.6 以上を使う必要があります。
 - jperl : 2 バイトの漢字を 1 文字として扱うことができる (jperl にはプラットフォームによって色々なバージョンがあるらしいので注意が必要)
 - perl5.6 : utf-8(マルチバイト) を扱うことができる
perl5.6 がリリースされた現在では、perl5.6 を使うのが正解でしょう。
perl5.6 なら utf-8 を処理できるので、マルチバイトを処理する正規表現が直接記述できます。
- この後の話は、perl5.6 + Jcode.pm を前提に進めていきます

4 getcode メソッドと convert メソッド

- jcode は getcode と convert メソッドが基本です。

4.1 jcode.plレガシーインターフェースとオブジェクト 指向インターフェース

- Jcode.pm を使用する場合 jcode.pl 風のレガシーインターフェースと、オブジェクト指向のインターフェースの両方が使えます。
- ここでは、jcode.pl 風のインターフェースでの使いかたをメインに紹介します。

4.2 `getcode` メソッド - エンコードを調べる

- `@result = getcode(\$line);`
 - `$line` のエンコード名を、"jis", "sjis", "euc", "ucs2", "utf8", のいずれかで返します。 `$line` 中にバイナリキャラクタを見つければ、"binary"を返します。
 - この関数をリストコンテキストで使うと、2つの要素を含むリストを返します。第1要素は、`$line` 中で、予想されているエンコードに一致したバイト数です。第2要素は、`$line` のエンコード名です。

4.3 `convert` メソッド - 任意のエンコードに変換する

- `convert(\$line, [$ocode, $icode, $opt])`
 - `$line` を、`$ocode` に与えられたエンコードに変換します。
 - 第2引数 `$ocode` には、変換したいエンコードを "jis", "sjis", "euc", "ucs2", "utf8" のどれかで与えます。
 - `$opt` は、半角カナ等の処理に関するオプションです。(詳細は省略します。)

5 サンプルコードによるデモ

- Jcode の説明のために簡単なサンプルコードを作成しました
- 具体的にコードと動作を示します

5.1 perl5.6 のテスト

- perl5.6 の utf-8 対応がどんな状況かを見てみます
- ソースコード `utf_test.pl`¹

5.2 文字コード判別 (`getcode` メソッド使用)

- 文字コードの判別の実験を行います。
- ソースコード `jcodeis.pl`²

¹`code/utf_test.pl`

²`code/jcodeis.pl`

5.3 nkfもどき (convert メソッド使用)

- nkfのようなフィルターを作ってみます。
- ソースコード `nkf.pl`³

6 付録:その他のリソース

6.1 perlがインストールされている環境で見れる資料

- perldoc ドキュメント (コマンドラインで `perldoc Jcode` してみよう)
 - この資料では触れていませんが、ほかにも全角・半角変換や MIME データの作成など便利な機能があります。

6.2 インターネット 上のリソース

- `pkf`
歌代和正さん <utashiro@ij.ad.jp> 作の nkf の perl 版です。
`ftp://ftp.ij.ad.jp/pub/IIJ/dist/utashiro/perl/pkf-2.1`⁴
- `Jcode.pm`
DAN Kogaidan <kogai@dan.co.jp> さん作で、`jcode.pl` をモジュール化したものです。
`http://openlab.ring.gr.jp/Jcode/index-j.html`⁵
`CPAN/authors/id/D/DA/DANKOGAI`⁶
- 「`jcode.pl` の私的な解説書」
`jcode.pl` の日本語訳版 (非公式)⁷
- 「Manpage of UNICODE」
UNICODE の manpage(日本語)⁸

³`code/nkf.pl`

⁴`ftp://ftp.ij.ad.jp/pub/IIJ/dist/utashiro/perl/`

⁵`http://openlab.ring.gr.jp/Jcode/index-j.html`

⁶`ftp://ftp.dti.ad.jp/pub/lang/CPAN/authors/id/D/DA/DANKOGAI/`

⁷`http://www.mikeneko.ne.jp/~lab/kcode/jcode.html`

⁸`http://www.linux.or.jp/JM/html/LDP_man-pages/man7/unicode.7.html`

6.3 書籍

- 「日本語情報処理」
 - 著者:Ken Lunde
 - ISBN 4-89052-708-7
 - 本体価格:4893 円
 - 概要:
コンピュータによる日本語処理について、JIS 漢字コードや EUC、Unicode、各メーカー漢字コードなどの各コード体系、アプリケーションにおける日本語特有の問題についての対処法など詳解。
※原書が 3 年前に絶版になっているので、この翻訳本も入手できないかもしれません。
- 「CJKV Information Processing (Chinese, Japanese, Korean & Vietnamese Computing)」
 - By Ken Lunde
 - 1st Edition December 1998
 - 1-56592-224-7, Order Number: 2247
 - 1125 pages, \$64.95
O'Reilly の紹介ページへ⁹
- 本ドキュメントの PDF 版はこちら¹⁰

⁹<http://www.oreilly.com/catalog/cjkvinfo/>

¹⁰[index.pdf](#)