



文字化け

とみたまさひろ

*bit*の会

2015-06-06

自己紹介



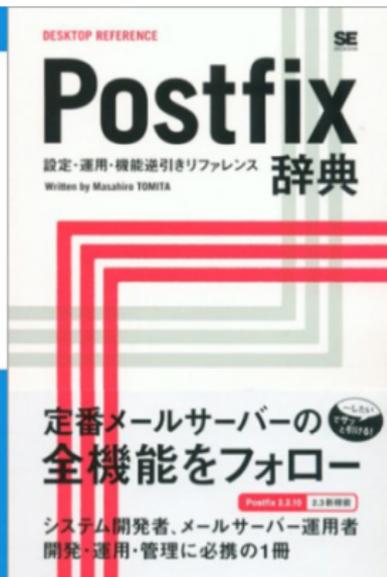
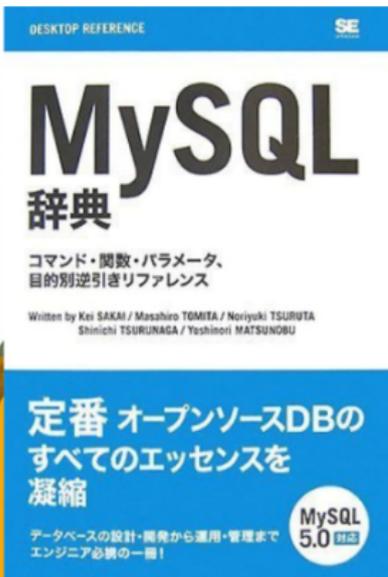
- とみた まさひろ
- 長野県北部在住プログラマー
- 言語: C_(1989~) Ruby_(1998~)
- 日本MySQLユーザ会代表
- 長野ソフトウェア技術者グループ(NSEG)

自己紹介



- <http://tmtms.hatenablog.com>
- <http://twitter.com/tmtms>
- <https://github.com/tmtm>
- MySQL 3.21 の日本語対応 (1998)
- MySQLのRubyバインディング作成 (1998)

執筆書籍



自己紹介



- もっともRTされたツイート



とみたまさひろ
@tmtms

「髯」なんて文字が！「うさぎ髯」「かめ髯」みたいに使うのか！…って思ったら、通貨単位だった。



5,020
リツイート

2,823
お気に入り



12:56 - 2014年10月19日

自己紹介



- もっともブックマされたブログ



@tmtms のメモ

id:tmtms

Hatena Blog

メールアドレスの正規表現

たまにメールアドレスの形式を正規表現で表すのは不可能とかというのを目にするのですが、そんなことはありません。入れ子がなければたいの文字列の形式は正規表現で表すことができます。ということで、RFC5321, 5322 からメールアドレスの正規表現を書い



2014-09-09 01:26 ★6 **276 users**

宣伝その1 NSEG



- <http://nseg.jp>
- 長野のIT技術者のゆるい集まり
- 2010年2月発足
(発起人:おびなたさん、しむやさん、おかもとさん)
- 毎月勉強会開催(今までに63回)主に長野市
- 「理論から学ぶデータベース実践入門」読書会 (隔週水曜日) at ギークラボ長野

宣伝その2 ギークラボ長野



- <http://geeklab-nagano.com>
- 県庁近く
- 無料で利用できる作業スペース
- 電源 & WiFi & Pepperくん あり
- 6/13 ハンズオン「はじめての Unity ～2Dゲームを作ってみよう～」





文字化け

文字化けを直してみた



残念ながら現バージョンのWindowsでは文字化けをなおすことは出来ません。
2025年発売予定のWindowsでは対応します。
このトラブルシューティングでは、
このような問題の原因を突き止め、
問題を解決する手順を示します。
質問の答えをクリックしてください。
手順に従って進みながら問題を解決できます。

どうしますか？

- 仕方がないから「ダイアログで遊ぼう」を閲覧。
- 「渡部シンイチのDejavu WORLD」を閲覧。



文字化けの原因

1. 文字コードが正しくない

文字コード



- Charset, 文字集合
- エンコーディング方式
- シフトJIS, 日本語EUC, UTF-8 等
- 文字のバイト表現

日本語の文字コード



- UTF-8 (Unicode 今は普通はこれ)
- SHIFT_JIS (Windows)
- EUC-JP (昔の UNIX)
- ISO-2022-JP (メール)

同じ文字でも異なるコード



「あ」

- UTF-8 (E3 81 82)
- EUC-JP (A4 A2)
- SHIFT_JIS (82 A0)

同じバイト列でも別の文字



C2 A9

- UTF-8 「©」
- EUC-JP 「息」
- SHIFT_JIS 「ツウ」



**バイト列だけでは
文字コードはわからない**

ところで



日本語文字のことを「**2バイト文字**」と言ってませんか？

UTF-8は日本語はだいたい**3バイト**

- 「あ」(E3 81 82)
- 「ア」(EF BD B1)



文字化けした文字列の 元の文字コードの見分け方



慣れるとパッと見でわかる

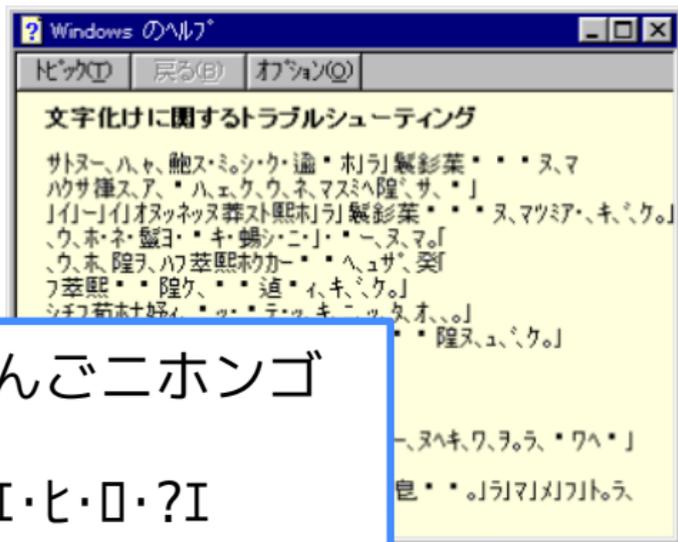
EUC-JP を SHIFT_JIS として表示



半角カナが多い

日本語にほんごニホンゴ

ニ?ワク?ヒ、ロ、?I・ヒ・ロ・?I



UTF-8 を SHIFT_JIS として表示



画数の多い漢字の中に半角カナが少々混じってる

日本語にほんごニホンゴ

譌・潜ゃ隠槭 ↓ 纏サ纏薙 # 縯九?縯ウ縯工

ISO-2022-JP の ESC 落ち



ASCII文字だけで構成されて「\$B」「(B」がある

日本語にほんごニホンゴ

?\$BF|K\8l\$K\$[\$s\$4%K%[%s%4?(B



文字化けの原因

2. 文字コードが不明



**自動判定もできるけど
完全じゃない**

同じバイト列でも別の文字(再掲)



C2 A9

- UTF-8 「©」
- EUC-JP 「息」
- SHIFT_JIS 「ツウ」

自動判定



- バイト列が文字コードの正当な範囲にあるかどうかで判定
- 文字列が短いと難しい
- 文字列が長ければ精度は上がる
- へんなバイトが混在してたらアウト
- 日本語じゃないのに日本語と誤判定したり

EUC - Extended Unix Code



- EUC-JP : 日本語EUC
- EUC-KR : 韓国語EUC
- EUC-CN : 簡体字中国語EUC

文字コードの範囲は同じだけど文字が違う

- BB FA : 字(JP) / 샐(KR) / 机(CN)

文字境界



- EUC
 - 1バイト文字 (00-7F) ← ASCII
 - 2バイト文字 (A1-F4 | A1-FE)
 - 文字列の先頭から見ないとわからない
- SHIFT_JIS
 - 1バイト文字 (00-7F A1-DF) ← JISX0201
 - 2バイト文字 (81-9F E0-FC | 40-7E 80-FC)
 - **2バイト目に ASCII 範囲含んでてやばい**

文字境界



- UTF-8
 - 1バイト文字 (00-7F) ← ASCII
 - 2バイト文字 (C2-DF | 80-BF)
 - 3バイト文字 (E0-EF | 80-BF | 80-BF)
 - 4バイト文字 (F0-F7 | 80-BF | 80-BF | 80-BF)

文字境界判別しやすい



文字化けの原因

3. 機種依存文字



- いわゆる「JISコード」
- 日本語メールで使われる文字コードは未だに ISO-2022-JP が主流
- \ と ¥ を使い分けできる
- ISO-2022-JP に無い文字
 - ① ② ③ I II III (株) kg cm 高 崎 ｶﾞｶﾞ



**ISO-2022-JP に無い文字を
ISO-2022-JP と偽ってメールする
奴がいる**



文字化け



昔の Mac だと ① が (月) に見えたり



だいたいマイクロソフトが悪い

MS の ISO-2022-JP



- CP50221
- ISO-2022-JP に無い文字を含む
 - ① ② ③ I II III (株) kg cm 高 崎 ｶｶｶ
- \ と ¥ の区別がつかない



まともなメールアプリが 「ISO-2022-JP」を信じると文字 化け



まともなメールアプリが責められる 「Outlookだと見えるのに」



ISO-2022-JP は CP50221 と みなして表示



ISO-2022-JP を ISO-2022-JP として扱うアプリが絶滅

文字コードの置き換え



- ISO-2022-JP : CP50221
- EUC-JP : CP51932
- SHIFT_JIS : CP932



だいたいマイクロソフトが悪い



文字化けの原因

4. フォントが無い







対応フォント入れれば解決



発表の途中ですがお知らせです



FAQ: 下のウサギとカメは何？

Rabbit

- Ruby製プレゼンツール
- <http://rabbit-shocker.org/>
- ウサギとカメはタイムキーパー
- カメに追い抜かされなければ時間内
- プレゼンがつまらなくても和む
- ソースはテキスト(RD / Markdown)
- PDF ビューアとしても利用可





Ruby

Ruby



- プログラミング言語
- オブジェクト指向スクリプト言語
- オブジェクト毎に異なる文字コードが可能
- ファイル毎に異なる文字コードが可能
- 嫌な予感…

ファイル



同じファイルからの読み込みでも異なる文字コードになることも

```
f = File.open("何か.txt", "r:utf-8")  
f.gets      #=> 1行文字列 UTF-8  
f.read(10)  #=> 10バイトデータ ASCII-8BIT
```

異なる文字コード同士



```
utf8 = "ほげ"  
sjis = "ほげ".encode("cp932")  
utf8 == sjis          #=> 偽  
utf8 + sjis          #=> エラー  
utf8 =~ /#{sjis}/    #=> エラー  
  
utf8 = "ASCII"  
sjis = "ASCII".encode("cp932")  
utf8 == sjis         #=> 真
```



混ぜるな危険！



全部 UTF-8 に統一すれば安全



MySQL



オープンソースの RDBMS

文字コード



- クライアントライブラリ
- クライアント-サーバー接続
- データベース
- テーブル
- カラム

…毎に設定可能



嫌な予感…

utf8 と utf8mb4



- UTF-8 文字コード
- utf8 は 3バイトまで
- utf8mb4 は 4バイトまで
- 絵文字(📖や🍺)は4バイト

utf8カラムに4バイト文字を入れようとする



接続が utf8 の場合:

```
mysql> insert into t (c) values ('今日は📖と🍺');  
Query OK, 1 row affected, 1 warning (0.09 sec)  
mysql> select * from t;  
+-----+  
| c      |  
+-----+  
| 今日は |  
+-----+
```

utf8カラムに4バイト文字を入れようとする



接続が utf8mb4 の場合:

```
mysql> insert into t (c) values ('今日は📖と🍺');  
Query OK, 1 row affected, 1 warning (0.09 sec)  
mysql> select * from t;  
+-----+  
| c      |  
+-----+  
| 今日は?と? |  
+-----+
```

utf8mb4カラムに4バイト文字を入れようとする

接続が utf8mb4 の場合:

```
mysql> insert into t (c) values ('今日は📖と🍺');
Query OK, 1 row affected (0.06 sec)
mysql> select * from t;
+-----+
| c                |
+-----+
| 今日は📖と🍺      |
+-----+
```

utf8mb4カラムに4バイト文字を入れようとする

接続が utf8 の場合:

```
mysql> insert into t (c) values ('今日は📖と🍺');  
Query OK, 1 row affected, 1 warning (0.06 sec)  
mysql> select * from t;  
+-----+  
| c          |  
+-----+  
| 今日は????と?? |  
+-----+
```

4バイト文字を utf8 接続から取り出すと



```
mysql> select * from t;  
+-----+  
| c      |  
+-----+  
| 今日は?と? |  
+-----+
```

「？」の調査



```
mysql> select hex(c) from t;
```

```
+-----+  
| hex(c) |  
+-----+  
| E4BB8AE697A5E381AFF09F8DA3E381A8F09F8DBA |  
| E4BB8AE697A5E381AF3F3F3F3FE381A83F3F |  
+-----+
```

←ちゃんと入ってる
←データが「？」



混ぜるな危険！



全部 utf8 / utf8mb4 に統一すれば安全



まとめ



**歴史的経緯により日本語には複数の
の文字コードが使用されている**



これからは UTF-8 を使えばみんな
ハッピー



本当に？



Unicode の闇

中国語と日本語で文字が統一



写真
写真

合成文字



- が (E3 81 8C)
- が (E3 81 8B E3 82 99)
- 「か」 + 「゛」の二文字
- 比較には正規化が必要

色付き絵文字の肌色問題



- 絵文字は日本発祥
- 肌色が一種類
- 「人種差別だ！」
- 合成文字で解決



これからの絵文字の実装指針、UTR #51“Unicode Emoji”とはなにか -INTERNET Watch
http://internet.watch.impress.co.jp/docs/special/20150131_686161.html



俺達の戦いはこれからだ！



おわり