

Punycode

山本和彦
(株)インターネットイニシアティブ
kazu@iij.ad.jp

Punycode とは？

- ユニコード
 - puny は「ちっぽけな」の意味
- Unicode である IDN を ASCII の図形文字へ変換する
 - IDN = Internationalized Domain Name
- IETF WG は ACE から Punycode を採択
 - JPNIC (現 JPRS) が提案していたのは RACE
 - ACE = ASCII Compatible Encoding
 - RACE = Row-based ASCII Compatible Encoding
- RFC 3492
 - March 2003

例題

- 日本語 → xn--wgv71a119e
 - "xn--" が Punycode の始まり
 - Punycode の部分は、 "-", 0~9, A~Z, a~z
- 3年B組 → xn--3b-w52dz04i
 - ASCII の図形文字が混ざると "-" が区切りとなる
- 符号化と復号化を体験したい人は
 - <http://punycode.jp/>

Punycode の目標

- 一対一の対応
 - IDN の文字列 \leftrightarrow Punycode で符号化された文字列
- 符号化の結果が短いこと
 - ドメイン・ラベルは 63文字まで
- 簡潔なこと
 - 本当？
- Unicode の基本ラテン文字は、それ自身で表現
 - $u+0000 \sim u+007F \rightarrow 0x00 \sim 0x7F$

符号化の概要

- 例
 - 3年B組金八
- Unicode
 - u+0033 u+5E74 u+0042 u+7D44 u+91D1 u+516B
- 基本ラテン文字を前へ
 - u+0033 u+0042 u+5E74u+7D44 u+91D1 u+516B
 - "3b-" + u+5E74 u+7D44 u+91D1 u+516B
- 小さい順に並べ替え
 - "3b-" + u+516B u+5E74 u+7D44 u+91D1
- 差分の計算
 - "3b-" + 20843 3337 7888 5261
- ASCII へ
 - "3b-wz4c970c5k0b50za"

(注意) 正確ではありません

疑問

- 元の位置は、どうやって知るのか？
 - 基本ラテン文字を前に送っている
 - 並べ替えている
- 区切りは、どこか？
 - "wz4c970c5k0b50za" のどこが「年」か？

元の位置

- 差分に元の位置を加える
 - 差分 × 元の文字列の大きさ + 元の位置
- 考察
 - 元の文字列の大きさ分ビット数を使うより、元の文字列の大きさを掛ける方が小さい？
 - 例) 6 で 3 ビット消費するより、6倍する方が小さい？

(注意) 正確ではありません

一般可変長整数

- 普通の整数
 - 例) ... 152437
 - 7 or 37 or 437 or 2437... ?
- 一般可変長整数では閾値を設ける
 - 最上位の桁のみが閾値より小さくなる
 - よって区切りが分かる
- 一般可変長整数の例
 - 一般可変長整数) ... 1 5 2 4 3 7
 - 閾値) ... 5 5 2 5 3 2
 - 152 と 437

桁の意味

- 一般式
 - $x_n \times w_n$
- 普通の整数
 - $w_n = 10^n$
 - $x_n \times 10^n$
- 一般可変長整数
 - $w_0 = 1$
 - $w_n = w_{n-1} \times (10 - t_n), \text{ for } n > 0$
 - t_n は閾値
- 例 437 [532]
 - $w_0 = 1$
 - $w_1 = 1 \times (10 - 2) = 8$
 - $w_2 = 8 \times (10 - 3) = 56$
 - $4 \times 56 + 3 \times 8 + 7 \times 1 = 255$

閾値

- 閾値を決める式
 - $t_n = 10 \times (n + 1) - bias$
- さらに $bias$ を決める式がある...

Mew での実装

- まともな Punycode ライブラリがない
 - punycode.el は外部コマンドを呼び出す
 - → 自前で作る
- ブラウザへの URL 受け渡し
 - Mac OS X ではコマンド "open" を使う
 - "open" は、引数の URL に Unicode を許さない
 - punycode のままで渡す必要がある
- メールのヘッダ
 - とりあえず放置
- メールの本文
 - ISO-2022-JP などで書かれた IDN の URL
 - Punycode の URL

Mew での実装

