

Chaon 実装の歩み : XEmacs CHISE から libchise へ

守岡 知彦

京都大学 人文科学研究所 附属 漢字情報研究センター

はじめに

Chaon 実装開発の歩み

1. UTF-2000 以前
2. XEmacs UTF-2000 の登場
3. CHISE: 環境への展開

背景(1) 1990年台前半頃の状況

計算機の処理能力の向上によって多字・多言語処理が現実化してきた

1990年 JIS X 0208:1990, JIS X 0212 制定

1990年頃? CDP データベースの開発開始

1991年 Mule の開発開始

1993年 Mule 1.0

ISO/IEC 10646-1:1993 制定

Windows NT 3.1

1994年 Windows NT 3.1 日本語版

1995年頃 IRIZ 漢字ベース

→ 大規模コード、統一コード待望論

背景(2) Code Wars

- 1984年 ISO 10646 の開発開始
- 1987年? ISO DP 10646
- 1990年 JIS X 0208:1990, JIS X 0212 制定
ISO 1stDIS 10646 vs. Unicode 1.0
- 1991年 (芝野の野望!?)
ISO 1stDIS 10646 否決
CJK-JRG 発足、統合漢字 v1.0
- 1992年 ISO 2ndDIS 10646
- 1993年 ISO/IEC 10646-1:1993 制定
- 1996年 ハングルの大移動、UTF-16, Unicode 2.0
- 1997年 JIS X 0208:1997

→ 文字コードをめぐる宗教対立!?の激化

背景(3) 漢字符号化の困難さの認識

代替アーキテクチャの希求

- 部品による漢字合成
 - 中央研究院の CDP (1990 年頃)
 - fj.kanji での盛り上がり、漢字 ML 設立 (1994 年)
 - グリフ合成の問題、文字表現力の問題
- 文字符串に依らない文字表現
 - SGML の実体参照の利用
 - CES 依存性は解決できても、CCS 依存性はなかなか解決できない
 - もっと抜本的な解決はないもんかいな

ラディカル・アプローチ

汎用文字コードを基礎にコンピューター・システムを考えるのではなく…

- 汎用じゃない文字コードを考えてみる（全部外字）
- すごく長い bit 長で文字を表しても良いかも
- *My Symbolic System*
 - シンボルを文字列ではなく画像で表現した Lisp 処理系を考えてみる
 - シンボルはアイコンで画面上に表現されている
 - 白紙窓に絵を書いて OK ボタンを押すと、その絵を表現とするシンボルが生成される
 - もし文字が必要なら、この仕組の中で定義する

UTF-2000

“My Symbolic System” のアイディアの内、とりあえず「文字を定義する」という部分を現実化してみよう

- 文字をオブジェクトとして扱う
 - 文字の持つ性質（文字素性）の集合で文字を表現する
- 文字列はオブジェクトの列にする
 - 整数に対する算術的変換 (ex. UTF-8) を使ってオブジェクト ID を符号化してマルチ・バイト列を作ることができる

UTF-2000 の現実化


- 1998年4月 utf-2000 mailing list 開設
- 1998年4月 UTF-2000 based on GNU Emacs 20.2.90
(g 新部氏による)
- 1999年5月 XEmacs UTF-2000 の実装作業開始
- 1999年6月 XEmacs 21.2.16 (Sumida)
UTF-2000 Version 0.2 (JR 難波)

2003年2月に“XEmacs UTF-2000”は
“XEmacs CHISE”と改称した

Chaon モデル


UTF-2000 のエッセンスを取り出したもの

- 文字を文字素性の集合（大域的に情報交換可能なもの）で表現
- 文字オブジェクト ID の機械的割り当て
- 文字の内部表現への直接アクセスの禁止



XEmacs CHISE

- XEmacs-Mule
に基づく多言語文書編集系
(実用的側面)
- 文字符串に依存しない
文字処理技術の試験実装および
テストベッド
(実験的側面)



XEmacs CHISE の特徴

- XEmacs に基づく Chaon モデルの試験実装
 - 文字素性データベース機能
 - 豊富な文字空間（最大約 10 億文字定義可能）
- XEmacs-Mule に対する上位互換性
 - 既存の Emacs Lisp package が利用可能
 - Mule-charset の拡張 (coded-charset)
 - coding-system の拡張

文字素性データベース機能

- 文字定義
- 文字素性の設定
- 文字素性の参照
- 文字素性による文字の検索

Mule-charset の拡張 (coded-charset)

- 文字オブジェクトと code point の写像・逆写像
- 内部表現に対する依存性の解消
- 4 byte 以内の任意の文字符号が利用可能
- 文字素性の一種として扱われる
- 別名
- 繙承

coding-system の拡張

- UTF-8 など Unicode 系 CES
- CCS 変換に用いる coded-charset を指定可能
- 実体参照変換
- 文字結合（途中）

XEmacs CHISE の問題点・課題

- データベースの整備が必要
- 主記憶を浪費する
- XEmacs に閉じてしまっている

データベースの整備

- XEmacs CHISE 附属の文字データベース
 - 自由に利用可能な各種データベースを統合・整理したもの
 - 約 10 万字 (define-char 換算) 収録
 - 漢字を細かく分離している (やりすぎ!?)
- 漢字構造情報データベース

漢字構造情報のデータベース化

U-00020020	甘	廿ノノ
U-00020021	秃	一ノ先
U-00020022	疋	一ノ此
U-00020023	迺	一ノ口ノ几
U-00020024	迺	大ノ大
U-00020025	迺	一ノノ一
U-00020026	州	一ノ州
U-00020027	巴	三ノ
U-00020028	巴	下ノ及
U-00020029	巴	兀ノ丁
U-0002002A	𠂇	甘ノ
U-0002002B	𠂇	甘ノノ
U-0002002C	𠂇	丙ノ人
U-0002002D	采	刀ノ
U-0002002E	𠂇	一ノ八ノ口ノ
U-0002002F	𠂇	ノノ

漢字構造情報データベース

- 利用可能な既存のデータベースをなるべく変換
 - CDP (Chinese Document Processing) Database (台灣 中央研究院の謝清俊らによる；約 55000 字収録)
 - CBETA 外字データベース (台灣の中華電子佛典協會 (CBETA) による；約 13000 字収録)
- 新規入力 (このために部品および IDC 入力用の四角號碼 quail を開発 [Wittern 氏による])
- 現在、UCS 収録の約 7 万字に対して一応入力完了
- cvs.m17n.org:/cvs/chise で公開中 (ids module)
- GPL で利用可能


主記憶の節約

- 内部表現の効率化
- 外部文字データベース機能の実現
 - XEmacs CHISE で定義した文字素性データを XEmacs の外部のデータベースに保存
 - 必要な時に必要な分だけデータを取って来る (lazy-loading 機能)

Berkeley DB を使用

XEmacs の外部への展開

文字データベースに基づく総合的な文書処理環境の実現



CHISE プロジェクト構想

文字データベースの共有化

- PostgreSQL ベースの文字データベース・サーバー実現の遅れ
 - TopicMaps の実装が難しかった
- 当面、現状の Berkeley DB ベースの文字データベースを共有することになった
 - Ruby/CHISE, Perl/CHISE の登場



- Berkeley DB の方が良いかも
- PostgreSQL 化よりも共通部分をライブラリ化を優先すべし→ libchise 構想

libchise の目標

CHISE 環境で共有される機能のライブラリ化

- XEmacs CHISE の機能のライブラリ化
 - 脱 Lisp 化
 - スケーラビリティ



- 階層モデルの定義
- データ形式の定義

CHISE 階層モデル

第4層 オブジェクト層

文字に対する抽象的なサービスの提供
(関数、 message 送信式、 TopicMaps 等)

第3層 構造データ層

複雑なデータ構造の実現 (S 式、 XML 等)
(記憶管理や型システムの実現)

第2層 文字層

素性名による文字データへのアクセスの実現
(C の文字列レベルに限定、記憶管理無し)

第1層 データソース層

(Berkeley DB や PostgreSQL などのデータベース)

データ形式

現状 文字素性値を構造化している

- 複数候補：集合を表現するリスト
- メタデータ：属性リスト

今後 なるべく文字素性値に

複雑なデータ構造を使わないようとする

→ 文字素性名の構造化

- 複数候補：素性名に選択指示子を付ける
- メタデータ：素性名にメタデータ指示子を付ける

libchise の現状

- 第2層の実装
 - 基本的なデータ参照機能の実装は完了
 - 書き込み機能、map 機能は近日中に実現予定
- libchise の利用
 - XEmacs CHISE の libchise 化（作業中）
 - libchise 版 Ruby/CHISE

今後の予定

- XEmacs CHISE 機能の libchise 化、第3,4層実装
- Kage 機能の libchise 化
- 文字素性データベースの再構築
- 文字素性データベースの libchise への移転
- 漢字の発音や意味に関する情報のデータベース化
- テキスト・データベースとの連携
- などなど