HDIC Viewer 2023 : 古辞書総合情報ポータルサイトの構築に向かって

劉　冠偉（東京大学史料編纂所）
2023年1月21日
シンポジウム「古辞書データ共有と拡張」

HDIC Viewerとは

- 最初は平安時代漢字字書総合データベース(HDIC)を公開・検索するためのインタフェースとして開発
- HDIC以外の古辞書データベースを追加
  - 夢梅本和玉篇
  - 本草和名
  - 大字典和訓
  - 一切経音義

HDIC Viewerの現状

- ページ数
  - 48
- API数
  - 40
- テーブル数
  - 20
- レコード数
  - 24万（古辞書関連データ）

今までの開発

- モデリング
  - ほとんどは表データのまま
- 設計
  - テキストDB
    - 検索のみ
    - 管理はRDBMSに直接操作
  - 画像DB
    - ローカル画像ファイル
- 実装
  - スタック（Stack）
    - 開発に利用するプログラミング言語、フレームワーク、ライブラリなど
    - PHP、MySQL、Laravel、Vue
  - HNG単字検索も同様に開発

課題・問題点

- 長年にわたって
  - 2015～現在
- 問題：
  - モデリング
    - DBそれぞれに異なる
  - 設計
    - テキストデータ検索のみ
    - 管理インタフェースがない
  - 実装
    - 開発パターンの不統一
      - テンプレート（バックエンドのみ）
      - フロントエンド・バックエンド分離
    - PHP
      - セキュリティー
- これ以上の拡張は難しい

スタック変更の試し

- ”辞書語彙データベース”の開発
  - 藤本灯科研（21H00529）
  - URL: https://kojisho.netlify.app/
  - 管理システム：https://portal.kojisho.com/admin/login/?next=/admin/
  - Django（Python）
  - Quasar（Vue3，JavaScript）
- 良いところ
  - 参考事例が多い
  - 管理サイトが内蔵
- 悪いところ
  - 重い（どっちも）
  - 開発言語が不統一
  - Quasarが不人気

辞書語彙データベース

- フロントエンド・バックエンドの分離
  - 当然、WEB　APIも提供
- 管理サイトによってデータの一括更新
  - エクセルファイルなど

開発上の不足

- モデリング
  - Django内蔵ORM
    - カスタマイズしにくい
- 設計
  - フロント側は検索のみ
- 実装
  - Python…
    - デメリットはJavaScriptではない
      - もちろん速度、タイプチェック、インデントなども嫌いけど

ポータルサイト的な存在は？

- HDIC Viewer、HNG単字検索、辞書語彙データベースの開発から分かったこと
  - （研究資源として）元データの形式は様々
    - 画像ファイル、ページURL、APIなどなど
  - 完璧なモデルは（僕が作れ）ない
    - 使いやすい、作りやすい、残りやすい
      - どっちの二つしかできない
  - 最初の設計によって拡張性が決まる
    - 作りながら考えよう…をやめましょう　→　HDIC Viewer
  - まずは日本古辞書関連データを集めてほしい
    - ポータルサイト

なんの情報の集合？

- 漢字情報ポータルサイトではない
  - 形・音・義以外
- 古辞書　の　情報　の　ポータルサイト
  - 複数の古辞書
    - さらに複数の出典
  - 画像とテキスト
  - 広い年代・形式
- ↑すぐには無理
  - データマイニング←モデリング←理論

設計（機能）

- テキストデータ管理
  - スキーマ
  - DBのCRUD
  - インポート・エクスポート
- 画像データ管理
  - 画像ファイル名と項目ID
  - 外部IIIFのURL
- 字形データ管理
  - GlyphWikiダンプデータの導入
  - 字形データ（Kage）の管理
- ユーザー管理
  - ユーザーデータ
  - 通知システム

設計（モジュール）

- データの管理
  - インポート・エクスポート
    - 自動化：GitHub、Dropbox；マルチ形式：プレインテキスト（ TSV、CSV、JSON）、Excel
  - バージョニング；ソフトドロップ
- 認証
  - JWT；ロール管理
- WEB API
  - Restful
- データモデル
  - マスター
  - 各自のテーブル
  - 構造化データの管理
- 画像管理
  - IIIFクライエント（外部）
  - JPEG・PNG画像ファイル（内部）
- 字体・字形管理
  - 字形データ：Kage形式

【これから】開発用のスタック

- 開発言語
  - JavaScript（TypeScript）
- データ
  - ORM：Prisma
- フレームワーク
  - バックエンド：NestJS
  - フロントエンド：NextJS（候補：Nuxt、最近React系が好きになった）
- デプロイメント
  - NodeJS環境
    - PM2で管理

実装の一例：字形データ管理（モジュール）

- 独立の字形管理システム
- 機能
  - GlyphWikiダンプデータの導入
  - 字形の作成・編集
    - GlyphWikiと同じエディタを利用
  - 字形画像生成
    - Kage → SVG；PNG
  - 字形の検索
    - Kageデータのパーサー
  -

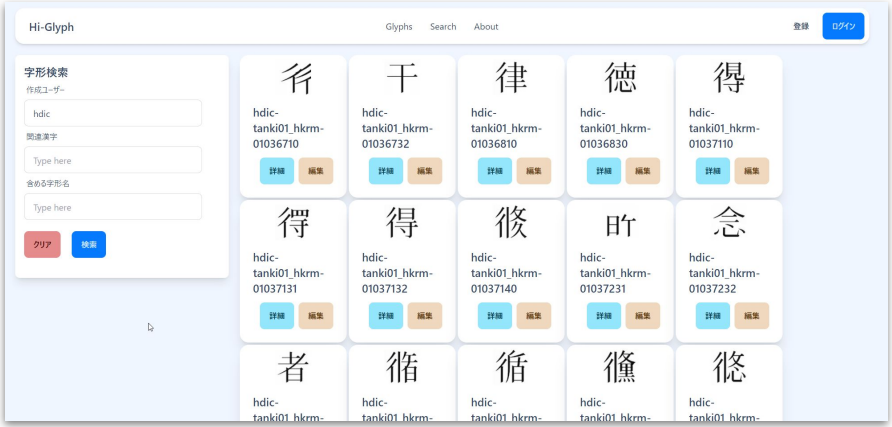

字形管理の必要

- 独自のサービス
  - GlyphWikiに依頼せず
- 著作権の明白
  - CC—BY予定
- 実験台
  - 字体字形サービスのテスト
  - GlyphWikiを汚染しない
    - 「hdic」で検索したらやばい量が ...

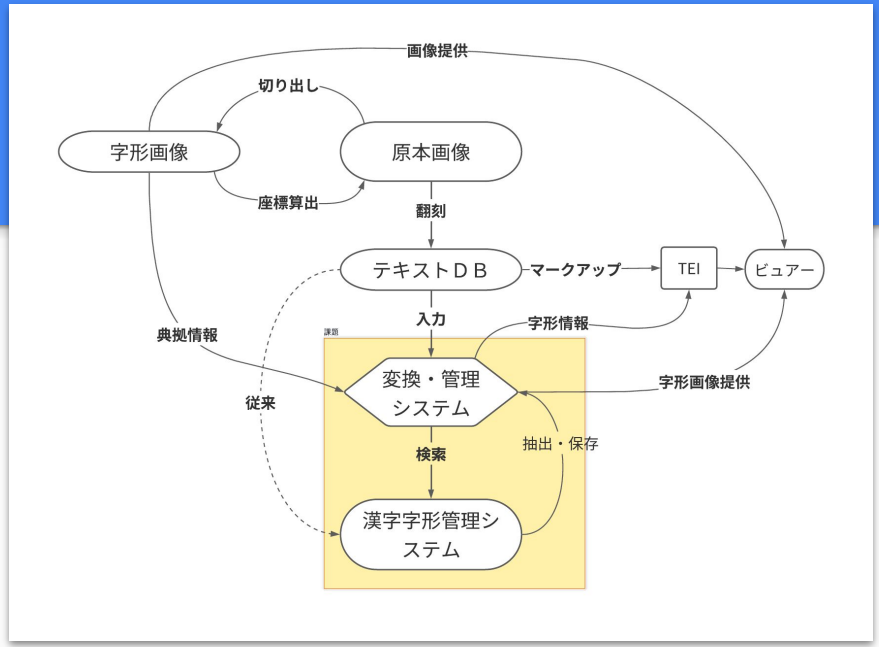

Kage Engine Online

- Kage-engineのライセンス
  - GPL
    - 感染性あり
  - 関係ある部分を独立なサービスとして開発
    - その部分のコードだけはGPLライセンス
- Kage-Server　開発版
  - ソース：https://github.com/toyjack/kage-server
  - URL：http://kage.lab.hi.u-tokyo.ac.jp/api/gen
  - 伝説の「KAGE/cgi サーバ仕様」を再現したい
    - http://kamichi.jp/spec.html
    - ずっと停止…
    - 結局簡易版だけを作った

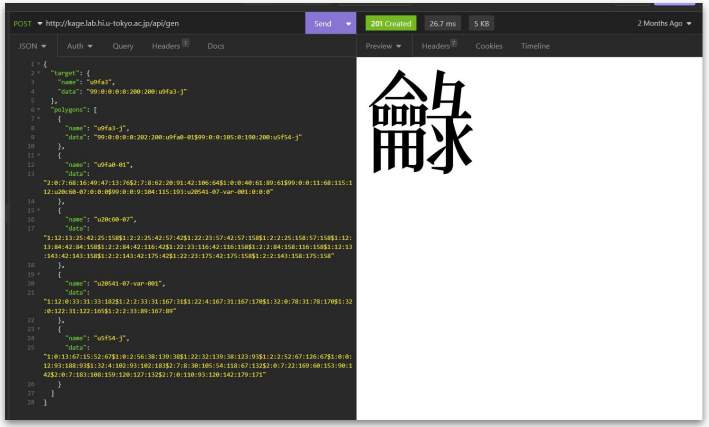

実装

- ライセンスが異なるのため
  - 4つのサービスに分け
    - ピンクはGPL
    - グレーはMIT

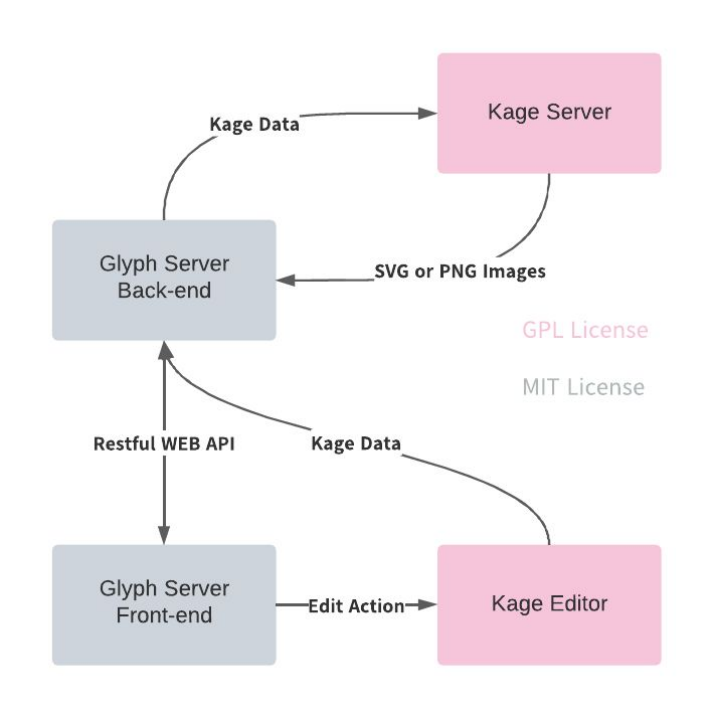

Glyph Server

- URL
  - バックエンドサーバー
    - https://glyph.lab.hi.u-tokyo.ac.jp/api/glyph/sandbox/png
  - ソースコード
    - https://github.com/toyjack/hi-glyph-server
  - フロントエンド
    - 開発中（不安定過ぎ ...
    - ソースコード
      - https://github.com/toyjack/hi-glyph-front
    - プロトタイプ
      - https://hi-glyph-front.vercel.app/
      - （よくフリーズしてしまう）

2023年度の展開

- 優先順位
  - ③データの管理
  - ⑤認証
  - ④WEB API
  - ②データモデル
  - ⑥画像管理
  - ①字体・字形管理

ご清聴ありがとうございました。